

**UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI**  
**Programa de Pós-Graduação em Educação**  
**Ramon Rocha Leite**

**APLICAÇÃO DO NSGA-II EM UMA ABORDAGEM MULTIOBJETIVO NA  
RECOMENDAÇÃO DE OBJETOS DE APRENDIZAGEM EM AMBIENTES  
INTELIGENTES PARA EDUCAÇÃO**

**Diamantina**  
**2020**



**Ramon Rocha Leite**

**APLICAÇÃO DO NSGA-II EM UMA ABORDAGEM MULTIOBJETIVO NA  
RECOMENDAÇÃO DE OBJETOS DE APRENDIZAGEM EM AMBIENTES  
INTELIGENTES PARA EDUCAÇÃO**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Educação, como parte dos requisitos exigidos para a obtenção do título de Mestre em Educação.

Orientador: Cristiano Grijó Pitangui

Coorientador: Alessandro Vivas Andrade

**Diamantina**

**2020**

Elaborado com os dados fornecidos pelo(a) autor(a).

L533a

Leite, Ramon Rocha

Aplicação do NSGA-II em uma abordagem multiobjetivo na recomendação de objetos de aprendizagem em ambientes inteligentes para educação / Ramon Rocha Leite, 2020.

56 p. : il.

Orientador: Cristiano Grijó Pitangui

Coorientador: Alessandro Vivas Andrade

Dissertação (Mestrado - Programa de Pós-Graduação em Educação) - Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2020.

1. Objetos de aprendizagem. 2. Otimização multiobjetivo. 3. Sistemas de recomendação. 4. Projeto instrucional. I. Pitangui, Cristiano Grijó. II. Andrade, Alessandro Vivas. III. Título. IV. Universidade Federal dos Vales do Jequitinhonha e Mucuri.

**CDD 371.3078**

Ficha Catalográfica – Sistema de Bibliotecas/UFVJM  
Bibliotecária: Viviane Pedrosa – CRB6/2641



**MINISTÉRIO DA EDUCAÇÃO**  
**UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI**

**RAMON ROCHA LEITE**

**APLICAÇÃO DO NSGA-II EM UMA ABORDAGEM MULTIOBJETIVO NA RECOMENDAÇÃO DE OBJETOS DE APRENDIZAGEM EM AMBIENTES INTELIGENTES PARA EDUCAÇÃO**

**Dissertação** apresentada ao programa de Pós-Graduação **em Educação** da Universidade Federal dos Vales do Jequitinhonha e Mucuri, **nível de Mestrado Profissional**, como requisito parcial para obtenção do título de **Mestre em Educação**.

Orientador: Prof. **Cristiano Grijó Pitangui**

Co-orientador: Prof. **Alessandro Vivas Andrade**

Data de aprovação 10/12/2020.

**Prof. Dr. Cristiano Grijó Pitangui - (UFVJM)**

**Prof. Dr. Alessandro Vivas Andrade - (UFVJM)**

**Profa. Dra. Luciana Pereira de Assis - (UFVJM)**

**Prof. Dr. Fabiano Azevedo Dorça - (UFU)**

**Diamantina - MG**



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI

RAMON ROCHA LEITE

APLICAÇÃO DO NSGA-II EM UMA ABORDAGEM MULTIOBJETIVO NA RECOMENDAÇÃO DE OBJETOS DE APRENDIZAGEM EM  
AMBIENTES INTELIGENTES PARA EDUCAÇÃO

**Dissertação** apresentada ao programa de Pós-Graduação **em Educação** da Universidade Federal dos Vales do Jequitinhonha e Mucuri, **nível de Mestrado Profissional**, como requisito parcial para obtenção do título de **Mestre em Educação**.

Orientador: **Cristiano Grijó Pitangui**

Co-orientador: **Alessandro Vivas Andrade**

Data de aprovação: 10/12/2020

**Prof. Dr. Cristiano Grijó Pitangui - (UFVJM)**

**Prof. Dr. Alessandro Vivas Andrade - (UFVJM)**

**Profa. Dra. Luciana Pereira de Assis - (UFVJM)**

**Prof. Dr. Fabiano Azevedo Dorça - (UFU)**



Documento assinado eletronicamente por **Luciana Pereira de Assis, Servidor**, em 14/12/2020, às 15:54, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Alessandro Vivas Andrade, Servidor**, em 14/12/2020, às 16:34, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Cristiano Grijó Pitangui, Usuário Externo**, em 15/12/2020, às 13:53, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Fabiano Azevedo Dorça, Usuário Externo**, em 15/12/2020, às 16:51, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufvjm.edu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufvjm.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0240284** e o código CRC **599F2A01**.

## RESUMO

Existem grandes repositórios de conteúdos na Internet que podem ser utilizados como fonte de recursos para promoção do *e-learning*. Porém, o volume de materiais disponíveis é muito grande. Para lidar com essa quantidade de itens, são utilizados os Sistemas de Recomendação, que selecionam os materiais mais adequados aos objetivos do estudante. Nesse contexto, o presente trabalho propõe uma abordagem multiobjetivo do problema de recomendação de Objetos de Aprendizagem (OAs) para atender a uma demanda de ensino, desde uma pequena seção de aprendizagem até um curso completo. Na abordagem proposta, uma solução não necessariamente cobre todos os conceitos estabelecidos pelo *design* instrucional. Na verdade, buscam-se soluções que tenham o menor custo e a maior quantidade de conceitos cobertos. O custo de cada OA é diferente para cada aluno, determinado a partir do seu estilo de aprendizagem e de avaliações feitas por outros estudantes com perfil semelhante daquele aluno. Todavia, existem dependências entre alguns conceitos estabelecidas pelo *design* instrucional que cada solução deve respeitar. A partir do conjunto de soluções geradas, o estudante escolhe aquela que melhor atende as suas expectativas. Para se obter soluções foi utilizado o algoritmo NSGA II no *framework* MOEA, testado em uma instância de problema gerada artificialmente. Foram criados dois métodos de inicialização da população, que determina para cada indivíduo valores aleatórios de cobertura e seleciona Objetos de Aprendizagem também de forma randômica. Os resultados obtidos foram conjuntos de até 19 soluções para instâncias com 200 conceitos e 10 dependências entre conceitos, bem como de até 6 soluções para instância com 20 conceitos e 2 dependências. Para cursos com 20 dependências, a quantidade de soluções obtidas foi menor, no máximo 10. Mostra-se importante a avaliação de outros algoritmos além do NSGA-II, bem como a necessidade de aprimoramento do algoritmo de geração da população inicial para obter mais soluções inicialmente viáveis. Um possível trabalho futuro é aplicar o problema em repositórios reais, no qual o custo de cada OA é obtido a partir de seus próprios atributos.

**Palavras-chave:** Objetos de Aprendizagem. Otimização Multiobjetivo. Sistemas de Recomendação. Projeto Instrucional.





## ABSTRACT

There are large repositories of content in the Internet that can be used as resources for e-learning. However, there are too much available materials. Recommender Systems are used to deal with these many items, which select the most suitable materials for the student's goals. The present paper proposes a multi-objective approach to the problem of Learning Objects (LOs) recommendation to meet a teaching demand, from a small learning section to an entire course. In the proposed approach, a solution does not necessarily cover all course subjects, established by the instructional design. In fact, solutions for a course are sought that have the lowest cost and the largest number of subjects covered. The cost of each LO is different for each student, based on his/her learning style, as well as assessments made by other students with a similar profile to that student. However, the instructional design also establishes dependencies between some subjects that each solution must respect. From the set of generated solutions, the student chooses the one that best meets his/her preferences and expectations. An artificial instance of that problem was tested, using the NSGA II algorithm in the MOEA framework. Two methods of population initialization were created, which determine for each individual random values of coverage and select Learning Objects randomly as well. The results obtained were sets of up to 19 solutions for instances of courses with 200 subjects and 10 dependencies, as well as sets up to 6 solutions for instance of courses with 20 subjects and 2 dependencies. For courses with 20 dependencies, the amount of solution obtained was smaller, at most 10. It's important to evaluate other algorithms in addition to the NSGA-II, as well as the need to improve the initial population generation algorithm to obtain more feasible solutions. A possible future work is to apply the problem in real repositories, in which the cost of each OA is estimated based on its attributes.

**Keywords:** Learning Objects. Multi-objective Optimization. Recommender Systems. Instructional Design.



|   |    |
|---|----|
| Figura 1 – Soluções ótimas locais e global . . . . .  | 23 |
| Figura 2 – Mapeamento de soluções em um problema de otimização combinatória multiobjetivo . . . . . | 24 |
| Figura 3 – Relação de dominância . . . . .  | 25 |
| Figura 4 – Exemplo de Fronteira de Pareto-Ótima e Fronteira de Pareto aproximada . .                | 26 |
| Figura 5 – Estrutura do Sistema de Recomendação Proposto. . . . .                                   | 30 |
| Figura 6 – Gráfico de soluções de uma execução dos testes na instância R3. . . . .                  | 41 |
| Figura 7 – Gráfico de soluções de uma execução dos testes na instância F2. . . . .                  | 41 |
| Figura 8 – Gráfico de soluções de uma execução dos testes na instância F3. . . . .                  | 42 |
| Figura 9 – Gráfico de soluções de uma execução dos novos testes na instância F3. . . .              | 45 |
| Figura 10 – Gráfico de soluções de uma execução dos testes na instância G2. . . . .                 | 46 |
| Figura 11 – Gráfico de soluções de uma execução dos testes na instância G3. . . . .                 | 47 |



## LISTA DE TABELAS

|   |    |
|---|----|
| Tabela 1 – Sugestões de estratégias de ensino e tipos de OA para cada estilo de aprendizagem. . . . . | 21 |
| Tabela 2 – Características das instâncias geradas para os testes . . . . .                            | 33 |
| Tabela 3 – Características das instâncias geradas para os novos testes . . . . .                      | 35 |
| Tabela 4 – Parâmetros dos testes executados . . . . .   | 39 |
| Tabela 5 – Média e desvio-padrão da cardinalidade das soluções . . . . .                              | 40 |
| Tabela 6 – Média e desvio-padrão do hipervolume das soluções . . . . .                                | 40 |
| Tabela 7 – Média e desvio-padrão do indicador $\epsilon_+$ das soluções . . . . .                     | 40 |
| Tabela 8 – Parâmetros dos novos testes executados . . . . .   | 43 |
| Tabela 9 – Média e desvio-padrão do tempo de execução dos testes, em milissegundos .                  | 44 |
| Tabela 10 – Média e desvio-padrão da cardinalidade das soluções nos novos testes . . .                | 44 |
| Tabela 11 – Média e desvio-padrão do hipervolume das soluções nos novos testes . . .                  | 45 |
| Tabela 12 – Média e desvio-padrão do indicador $\epsilon_+$ das soluções nos novos testes . . .       | 45 |

## SUMÁRIO

|       |  |    |
|-------|--|----|
| 1     | INTRODUÇÃO . . . . .   | 11 |
| 2     | TRABALHOS RELACIONADOS . . . . .   | 15 |
| 3     | REFERENCIAL TEÓRICO . . . . .  | 19 |
| 3.1   | <i>Design</i> instrucional . . . . .   | 19 |
| 3.2   | Estilos de aprendizagem . . . . .  | 20 |
| 3.3   | Otimização . . . . .   | 22 |
| 3.3.1 | <i>Otimização Mono-objetivo</i> . . . . .  | 23 |
| 3.3.2 | <i>Otimização Multiobjetivo</i> . . . . .  | 23 |
| 4     | O PROBLEMA DE RECOMENDAÇÃO DE OBJETOS DE APRENDI-<br>ZAGEM MULTIOBJETIVO . . . . . | 27 |
| 4.1   | Exemplo de aplicação . . . . .   | 27 |
| 4.2   | Modelagem matemática . . . . .   | 28 |
| 4.3   | O Sistema de recomendação multiobjetivo . . . . .                                  | 30 |
| 4.4   | Cálculo do custo de um objeto de aprendizagem para cada aluno . . . . .            | 31 |
| 5     | METODOLOGIA . . . . .  | 33 |
| 5.1   | Testes preliminares . . . . .  | 33 |
| 5.2   | Testes com novos parâmetros . . . . .  | 35 |
| 6     | RESULTADO . . . . .  | 39 |
| 6.1   | Resultados dos testes preliminares . . . . .                                       | 39 |
| 6.2   | Resultados dos testes como novos parâmetros . . . . .                              | 42 |
| 7     | CONCLUSÃO . . . . .  | 49 |
| 8     | TRABALHOS FUTUROS . . . . .  | 51 |
|       | REFERÊNCIAS . . . . .  | 53 |
|       | ANEXO A – PUBLICAÇÃO . . . . .   | 57 |

## 1 INTRODUÇÃO

A demanda por cursos com conteúdos digitais educacionais tem crescido consideravelmente, seja pelo crescimento do ensino a distância, ou mesmo pela utilização cada vez maior das ferramentas de Tecnologia da Informação e Comunicação (TICs) nos cursos presenciais. Segundo o Censo Escolar da Educação Superior (INEP, 2019), o número de ingressantes em cursos de graduação a distância no Brasil tem crescido, enquanto nos cursos presenciais houve ligeira queda desde 2015. O total de ingressantes no curso de graduação a distância representou 40% em 2018. Tal índice era de 20% em 2008.

Esse crescimento dos cursos não-presenciais são acompanhados também pela mudança no tipo de material utilizado. O Relatório da Associação Brasileira de Educação a Distância de 2018 (ABED, 2019) mostrou que, nos cursos a distância e semipresenciais, os livros impressos têm tido sua utilização reduzida, dando lugar a novos recursos educacionais digitais, como os *e-books*, *podcasts* outros tipos de áudios, teleaulas e outros tipos de vídeos.

Mesmo nos cursos presenciais, a utilização das TICs tem sido considerada como fundamental para o processo de ensino e aprendizagem (GILL; DALGARNO, 2017). Essa mudança tecnológica no âmbito educacional gera a necessidade de se criar metodologias e estratégias para lidar com esta nova realidade, inclusive para produção dos conteúdos educacionais.

Existe uma grande quantidade de conteúdo educacional disponível na Web. A Wikipédia, por exemplo, possui mais de 6 milhões de artigos em inglês, além de mais de 1 milhão de artigos em língua portuguesa (WIKIPEDIA, 2020). Neste mesmo sentido, o YouTube, a maior plataforma de compartilhamento de vídeos *online*, é atualizada, a cada minuto, com cerca de 500 horas de conteúdo sobre as mais diversas áreas de conhecimento (APPS, 2020).

Grande parte desses conteúdos disponíveis podem ser utilizados como recurso no âmbito educacional. O *e-Learning*, que Clark e Mayer (2016, p. 9) definem como a “instrução fornecida em um dispositivo digital, como um computador ou dispositivo móvel, que se destina a apoiar a aprendizagem”, tem ganhado importância, à medida que aumenta a quantidade de materiais disponíveis na Web, bem como a possibilidade de acesso a esses recursos, por meio da melhoria das conexões e da capacidade dos dispositivos computacionais. No entanto, é muito difícil avaliar e escolher manualmente dentre todo o montante de conteúdos, quais vídeos, textos, e/ou imagens são os mais adequados para serem utilizados.

Nesse sentido, em ambientes de vasta quantidade de materiais, são necessários mecanismos para selecionar e recomendar os conteúdos mais adequados aos usuários. Nesse contexto, são utilizados os Sistemas de Recomendação, os quais são responsáveis por encontrar e recomendar conteúdos úteis aos estudantes (HASSAN; HAMADA, 2016).

Para facilitar a sua utilização, os conteúdos educacionais são geralmente organizados em Objetos de Aprendizagem (OAs), os quais são definidos por IEEE (2002, p. 1) como “qualquer entidade, digital ou não, que possa ser utilizada para aprendizagem, educação ou capacitação”. Cada OA é geralmente composto pelo seu conteúdo propriamente dito, como

também por metadados que descrevem os seus atributos, tais como nome, autor, nível de dificuldade, ano de criação, tipo de conteúdo (vídeo, texto, imagem, etc.), entre outros.

Os OAs são organizados em repositórios, geralmente seguindo um determinado padrão de metadados que possibilita não somente a manipulação assertiva dos OAs, como também a interoperabilidade entre repositórios existentes. No campo educacional, alguns dos padrões mais conhecidos são IEEE LOM (IEEE *standard for learning object metadata*) (IEEE, 2002), IMS-CP (IMS, 2019) e Dublin-CORE (DCM *et al.*, 2008).

Várias pesquisas na área de Sistemas de Recomendação no âmbito Educacional têm sido desenvolvidas. Entre elas, situam-se os Sistemas de Recomendação de Objetos de Aprendizagem. Muitas abordagens recomendam os OAs que melhor correspondam aos anseios do estudante (SANTOS *et al.*, 2016). As técnicas mais comuns são recomendação baseada em conteúdo e a filtragem colaborativa.

A recomendação baseada em conteúdo se vale de outros itens que um determinado usuário já acessou e avaliou, para então recomendar novos itens, a partir da análise de semelhança dos atributos que houver entre eles (VENKATESH; SATHYALAKSHMI, 2020). Por sua vez, a filtragem colaborativa consiste em prover a recomendação de um item a um usuário a partir de avaliações que usuários com perfil semelhante fizeram acerca daquele item (SERGIS; SAMPSON, 2016).

Há ainda outras estratégias que buscam lidar com o problema de se possuir pouca informação sobre o usuário, o que dificulta a adoção das técnicas supracitadas para a recomendação. Essa dificuldade de identificar as preferências de novos usuários é conhecida como *cold start*. Muitas vezes há abordagens híbridas, que combinam distintas técnicas para realizarem a recomendação, de modo a se valer dos pontos fortes de cada estratégia e atenuar as suas respectivas limitações.

Uma das formas de se escolher os OAs mais adequados em um processo de recomendação é associar um custo a cada um deles. Desse modo, quanto menor for o custo associado a um OA, mais propícia é a sua recomendação. O cálculo do custo pode envolver diferentes atributos do OA, além de poder considerar os objetivos e o perfil de aprendizagem do estudante, bem como outras informações do contexto no qual a recomendação se dá. O cálculo do custo de um OA pode se dar, dentre outros modos, pela verificação do quanto ele se distancia ou está próximo das características de um OA ideal que é estabelecido.

Uma das importantes aplicações da recomendação de OAs é para sua utilização em cursos. Um curso inteiro, ou mesmo uma única seção de aprendizagem, contempla múltiplos conceitos, sendo necessário recomendar vários OAs para cobertura de todos os conceitos que o compõe. Nesse sentido, torna-se complexo lidar com a recomendação de vários OAs a partir de grande repositórios.

Tal complexidade se verifica porque há inúmeros fatores que devem ser analisados para se fazer uma boa recomendação. Do ponto de vista do estudante, é preciso tratar dos fatores associados ao custo que cada OA representa, a partir das suas necessidades e preferências.



Contudo, não se pode descuidar da tarefa de contemplar os conceitos previstos, conforme estabelecido no *design* instrucional (DI) do curso ou das seções de aprendizagem consideradas.

Muitas vezes, um conjunto de seções de aprendizagem sobre determinado assunto pode conter um número de conceitos além do que o aluno precisa ou está disposto a estudar. Nesse sentido, o DI pode prever a possibilidade de que não necessariamente todos os conceitos relacionados àquele assunto precisem ser estudados. Essa flexibilização pode ser admitida em um modelo de *design* instrucional contextualizado (DIC) (FILATRO; PICONEZ, 2004), no qual são admitidas mudanças *on-the-fly* em uma estrutura didática pré-concebida - nesse caso, o conjunto de conceitos.

É de se ressaltar, contudo, que a possibilidade supracitada necessita de cuidados do ponto de vista pedagógico. De modo geral, uma seção de aprendizagem é dividida em uma sequência de conceitos que segue uma lógica de aprendizagem. Dessa maneira, torna-se imprescindível em alguns casos que para um determinado conceito ser apresentado ao aluno, seus pré-requisitos sejam também apresentados. Isto posto, na possibilidade de haver configurações de cursos sem todos os conceitos inicialmente propostos, não se pode admitir a situação em que a abordagem de um assunto esteja presente em um possível curso sem a presença daqueles dos quais ele depende para ser bem compreendido.

Assim, torna-se viável a recomendação de um conjunto de OAs que não necessariamente cubra todos os conceitos de um curso, mas que respeite a relação de pré-requisitos supracitada. Na verdade, pode-se recomendar diferentes conjuntos de OAs, os quais contemplem diferentes estruturas de aprendizagem do ponto de vista conceitual. Essa coleção de possibilidades permite ao aluno escolher, com o auxílio de um tutor ou mesmo de um sistema de recomendação, aquela configuração que melhor atenda aos seus anseios, e então focar os seus esforços naquilo que realmente está interessado em aprender.

Isto posto, o presente trabalho propõe a modelagem de um problema de otimização multiobjetivo para a recomendação de diferentes conjuntos de OAs para uma seção de aprendizagem, num contexto de *design* instrucional no qual não necessariamente todos os conceitos previstos precisam estar cobertos, respeitadas as dependências existentes entre alguns deles. No problema proposto, buscam-se soluções com o menor custo e a maior cobertura de conceitos possível.

A justificativa para esta abordagem se deve ao fato da mesma apresentar não apenas uma, mas sim múltiplas possibilidades de solução, a partir dos objetivos de otimização considerados. Isso dá mais alternativas aos agentes envolvidos no processo de ensino-aprendizagem, para escolherem o conjunto de OAs que, além de atender as metas de aprendizado estabelecidas, possa melhor contemplar as expectativas e situações de contexto que porventura surjam.

O objetivo geral deste trabalho consiste em propor uma abordagem multiobjetivo para o problema de recomendação de objetos de aprendizagem, na qual nem todos os conceitos de uma seção de aprendizagem que se pretende estudar sejam obrigatoriamente cobertos, mas que haja relações de dependência entre alguns deles que precisam ser respeitadas.

Como objetivos específicos, pode-se mencionar:

- elaborar uma modelagem para formalização do problema proposto;
- propor e implementar uma técnica heurística para gerar um conjunto de soluções para o problema;
- testar a técnica proposta em um conjunto de instâncias, executando-a sob diferentes parâmetros em instâncias com diferentes características.

O algoritmo genético NSGA-II, implementado no *framework* MOEA (*Multi Objective Evolutionary Algorithm*) (MOEA, 2020), foi utilizado para solucionar o problema, executado por simulação em uma instância gerada artificialmente. Os resultados obtidos foram conjuntos de soluções mais diversos e numerosos para cursos com menos dependências entre conceitos. No entanto, para cursos com um número maior de dependências houve um número de soluções menor, principalmente sem valores médios de cobertura.

Foi possível constatar que o NSGA-II pode ser aplicado na geração de soluções para esse problema, haja vista que foram criados conjuntos de soluções diversos. Todavia, é preciso verificar se o desempenho de outros algoritmos evolucionários utilizados por trabalhos no campo da otimização multiobjetivo não é capaz de performar melhor. Além disso, faz-se necessário o emprego de métodos de inicialização que sejam capazes de gerar mais soluções viáveis que aqueles métodos que foram empregados.

Este trabalho está organizado da seguinte forma. O capítulo 2 apresenta trabalhos relacionados a esta pesquisa e o capítulo 3 alguns conceitos para melhor entendimento desse trabalho. O capítulo 4 apresenta de modo mais detalhado o problema proposto, com a sua respectiva modelagem. O capítulo 5 apresenta a metodologia experimental adotada para a obtenção dos resultados. O capítulo 6 apresenta os resultados experimentais desta pesquisa. Por fim, o capítulo 7 apresenta as conclusões e o capítulo 8 delinea algumas perspectivas de trabalhos futuros.

## 2 TRABALHOS RELACIONADOS

O presente capítulo tem por objetivo apresentar alguns trabalhos que possuem alguma relação com a abordagem proposta no presente trabalho, indicando as perspectivas já exploradas bem como possíveis lacunas a serem melhor trabalhadas.

Diversos trabalhos lidam com recomendações de um conjunto de OAs para atender a um conjunto de necessidades de aprendizagem. Muitos trabalhos implementam propostas voltadas para grandes repositórios, como Wikipédia e YouTube.

Medio *et al.* (2017) implementam uma plataforma de construção de cursos a partir de artigos da Wikipédia, utilizando um módulo que realiza a detecção automática de pré-requisitos entre as páginas da Wikipédia. As páginas selecionadas são ainda sequenciadas, o que ocorre através da associação de cada conceito a ser estudado com um tópico da Wikipédia. Os estilos de ensino de Grasha (GRASHA, 1996) também são utilizados para se fazer o sequenciamento, sendo armazenado em um grafo, que pode ser editado pelo professor do curso. Os autores mencionam pontos a serem melhorados no sistema, entre os quais estão complexidade, tempo e espaço de armazenamento consumidos para construção e atualização dos grafos que fazem os relacionamentos entre os conteúdos. Também destacam a possibilidade de estender esse mecanismo a outros repositórios, como Merlot ou Ariadne.

Júnior e Dorça (2018) também utilizam a Wikipédia como fonte de recursos de aprendizado a serem recomendados aos estudantes. Os autores constroem uma ontologia que possibilita a modelagem dos OAs e estudantes, os quais possuem um perfil definido de acordo com os estilos de aprendizagem do modelo Felder-Silverman (FELDER; SILVERMAN *et al.*, 1988). O processo de recomendação foi formalizado como um problema de cobertura de conjuntos, no qual se procura selecionar um conjunto de OAs que cubra todos os conceitos requisitados com o menor custo possível. O custo de um OA se dá pela comparação de distintos atributos desse OA em relação aos atributos de um OA ideal, os quais são definidos a partir de parâmetros determinados pelo professor do curso. Foi proposto um problema com alguns conceitos a serem cobertos, no qual pode-se observar pelos experimentos realizados que os OAs que compõem as melhores soluções são mais similares ao OA ideal em relação aos parâmetros que possuem um peso maior.

Ao invés de trabalhar com materiais textuais, Murad e Yang (2018), por sua vez, propõem a recomendação de Objetos de Aprendizagem que estão sob a forma de vídeos. Para tal, é apresentado um *framework* capaz de identificar o nível de conhecimento e perfil dos estudantes, e de posse dessas informações, recomendar vídeos que vão ao encontro das suas necessidades de aprendizado. A plataforma de vídeos inicialmente pensada para efetivação da proposta foi o YouTube. Inicialmente, os vídeos da referida plataforma são obtidos e então extraídos seus metadados, sendo classificados pela utilização de técnicas de mineração de dados de tópicos e subtópicos. Os perfis de estudantes são construídos a partir de informações de contexto, obtidas tanto através de *feedback* explícito do aluno, como também coleta de dados do comportamento do usuário para inferir o seu nível de conhecimento.

Bourkougou e El Bachari (2018) também utilizam os estilos de aprendizagem propostos por (FELDER; SILVERMAN *et al.*, 1988) para personalizar o aprendizado dos alunos, através da recomendação de OAs e sequenciamento dos mesmos. Porém, esse modelo é dinamicamente atualizado à medida que o estudante utiliza o sistema, o que é verificado a partir da mineração de dados dos logs gerados pelo sistema referente às ações e interações de cada usuário. A partir do perfil de usuário determinado, o sistema de recomendação sugere uma lista sequenciada de OAs que são considerados os mais apropriados para aquele perfil, o que é realizado por filtragem colaborativa. O sistema proposto foi testado em um caso real, no qual se verificou boa aceitação dos alunos do cenário de aprendizagem personalizado em relação ao modo tradicional, no qual uma mesma sequência de aprendizagem é gerada para todos os alunos.

Pireva e Kefalas (2017) trabalham a recomendação e sequenciamento de OAs não em um grande repositório específico, mas também no contexto do paradigma de *e-learning* em nuvem. O sistema de recomendação de OAs se baseia na clusterização hierárquica e filtra os OAs de acordo com o perfil e os objetivos dos alunos. Para cada estudante é determinado o tópico que é o seu objetivo de aprendizagem, assim como seu conhecimento prévio, ambos indicados através de um nível cognitivo da taxonomia de Bloom. A partir do ranqueamento dos OAs selecionados se obtém o caminho de aprendizagem personalizado, através de um sequenciamento de OAs, de acordo com o interesse e o nível de conhecimento de que cada aluno possui e pretende atingir. A abordagem proposta é empregada em um exemplo de curso da área de computação, o que demonstrou a sua aplicabilidade.

Venkatesh e Sathyalakshmi (2020) também propõe um sistema de recomendação personalizado, implementado com um algoritmo de otimização de colônia de abelhas para construção da estrutura de recomendação, que emprega ainda o algoritmo de clusterização k-médias. Os testes são executados em um sistema de gerência de aprendizagem (LMS) baseado no Moodle. O modelo de otimização busca identificar um caminho de aprendizado ideal para cada aluno, por meio de uma sequência de links que acessam OAs. O processo de recomendação é dividido em duas fases. Na primeira, as informações das sessões dos alunos são coletadas e agrupadas por técnicas de mineração de dados. Na segunda fase, há ainda a captura das preferências dos usuários nas sessões ativas quando a recomendação irá se efetivar, as quais são obtidas por intermédio das URLs que os estudantes acessam. Resultados obtidos em experimentos mostram que a abordagem proposta obteve melhores resultados que um algoritmo de busca gulosa.

Pelos trabalhos apresentados, percebe-se a existência de muitas pesquisas que buscam utilizar a grande quantidade de conteúdos disponíveis em repositórios *web* para empregá-los no *e-learning*. A recomendação dos OAs tem o objetivo de atingir da melhor maneira possível as necessidades de aprendizagem do aluno, seja do ponto de vista dos tópicos a serem abordados como do tipo de material mais adequado para cada perfil de estudante, passando inclusive pelo sequenciamento desses conteúdos em muitos casos.

Contudo, nas abordagens empregadas o foco da recomendação está principalmente em um único objetivo, que é o atendimento às metas de aprendizagem do aluno. A principal diferença no presente trabalho é que se tem uma abordagem multiobjetivo, em que a cobertura de todos conceitos do curso não é obrigatória, mas um objetivo a ser maximizado, em detrimento do custo geral da solução, que tende a aumentar à medida que mais OAs passam a compor a mesma. Ou seja, o *design* instrucional do curso flexibiliza a necessidade de que todos os conceitos sejam estudados. Contudo, o mesmo *design* instrucional também estabelece as relações de pré-requisitos entre alguns conceitos, que precisam ser respeitadas em cada solução considerada, mesmo quando nem todos os conceitos estiverem cobertos. Na verdade, tem-se uma relação de custo-benefício que permite ao aluno abrir mão de um curso totalmente completo em termos de conceitos para escolher uma solução com menor custo, de acordo com a sua realidade, expectativa, prioridade e preferência.



### 3 REFERENCIAL TEÓRICO

Este capítulo apresenta alguns conceitos importantes para melhor entendimento do trabalho proposto.

#### 3.1 *Design instrucional*

É crescente a utilização das ferramentas de Tecnologia da Informação e Comunicação (TICs) no processo de ensino e aprendizagem. Diante dessa realidade, tem aumentado a necessidade de se buscar estratégias e metodologias para produção dos conteúdos e materiais que são utilizados nesse ambiente, de modo a se atingir os objetivos e expectativas dos agentes envolvidos nesse processo, desde os professores até os alunos. Para se efetivar a tarefa podem ser empregados os modelos de *design* instrucional (DI).

Filatro e Piconez (2004, p. 2) descrevem *design* instrucional sendo “(..) compreendido como o planejamento do ensino-aprendizagem, incluindo atividades, estratégias, sistemas de avaliação, métodos e materiais instrucionais.” Sob uma perspectiva teórica, o *design* instrucional pode ser definido da seguinte maneira:

As teorias de design instrucional são orientadas ao design, descrevem métodos de instrução e as situações em que esses métodos devem ser usados, os métodos podem ser divididos em métodos de componentes mais simples e os métodos são probabilísticos (REIGELUTH, 1999 apud WILEY, 2002, p.7).

Tratando-se do DI como um processo, Filatro e Cairo (2015) distinguem sua abrangência em três níveis, conforme descrito a seguir:

- macro: define diretrizes de ações de aprendizagem para um sistema educacional inteiro, por exemplo, de toda uma instituição;
- meso: ações voltadas para uma dimensão mais específica, como um curso ou disciplina; e
- micro: trata das menores unidades de estudo que são propostas aos alunos.

Há diferentes naturezas de *design* instrucional. Filatro (2008) faz essa distinção em três diferentes tipos de DI: fixo, aberto e contextualizado.

No DI fixo há a divisão completa entre as etapas de planejamento e execução. Isso significa que o planejamento e produção de cada item que compõe o DI são completamente finalizados antes de se efetivar a ação de aprendizagem que será conduzida a partir daquele DI (FILATRO; CAIRO, 2015). É um modelo que traz pouca margem à personalização e está focado na reutilização dos conteúdos, uma vez que a localização e o sequenciamento dos mesmos é previamente conhecida.

O *design* instrucional aberto, por sua vez, trata o processo de ensino-aprendizagem como uma situação dinâmica e flexível. Segundo Filatro (2008, p. 212) no DI aberto, geralmente “(...) os artefatos são criados, refinados ou modificados durante a execução da ação educacional”. Por isso é também chamado de *design on-the-fly*, pois é construído em grande parte no momento de sua implementação.

O *design* instrucional contextualizado (DIC) apresenta um ponto intermediário entre as duas abordagens anteriores, na medida em que admite um processo de ensino com mudanças *on-the-fly*, sem no entanto abrir mão de elementos previamente programados. Isso permite que

um DI tenha algumas premissas definidas, sem deixar de prover mecanismos que se adaptem às características dos agentes do processo educacional. Nesse sentido, o DIC é definido como

a ação intencional de planejar, desenvolver e aplicar situações didáticas específicas que, valendo-se das potencialidades da Internet, incorporem, tanto na fase de concepção como durante a implementação, mecanismos que favoreçam a contextualização e a flexibilização (FILATRO; PICONEZ, 2004, p. 4).

O DI observado como um processo é geralmente dividido em etapas. Rodrigues, Rodrigues e Dias (2014) dividem tais etapas da seguinte maneira:

- Análise: identificação das necessidades, metas e os objetivos instrucionais, considerando as limitações existentes;
- Projeto: definição do conteúdo, instrumentos de avaliação e até mesmo planejamento de aulas para se atingir os objetivos de aprendizagem;
- Desenvolvimento: produção dos materiais projetados na etapa anterior;
- Implantação: capacitação e ambientação dos agentes envolvidos no processo de ensino-aprendizagem com a meta efetivar a proposta de DI concebida; e
- Avaliação: acompanhamento do sistema que foi proposto e implantado, com a sua revisão e manutenção a partir do *feedback* obtido.

Há outras formas de se entender as etapas do DI. Filatro e Piconez (2004), por exemplo, reúnem o projeto e desenvolvimento em uma única etapa. Argumentam ainda que, no *design* instrucional contextualizado, tais etapas ocorrem de modo recursivo.

O fato é que o DIC se mostra um modelo útil para guiar a produção de recursos didáticos digitais, uma vez que, conforme Moreira *et al.* (2019, p. 2)“(…)[o DIC] lida com situações didáticas que realçam a qualidade do contexto de aprendizagem no processo de planejamento, desenvolvimento e aplicação dessas situações”.

### 3.2 Estilos de aprendizagem

São várias as estratégias que se pode adotar no processo de ensino-aprendizagem. Atividades individuais ou em grupos, simulações, apresentações, estudos de caso são algumas das possibilidades, que podem igualmente utilizar os mais variados tipos de materiais, por exemplo textos, imagens, jogos e arquivos de áudio e vídeo. Contudo, as pessoas possuem diferentes preferências com relação ao modo como se apropriam e processam as informações para construção de novos conhecimentos (CURY, 2000). Isso provoca distintos níveis de aprendizagem nas pessoas, a depender de quais estratégias e materiais são utilizados. De fato, a compatibilidade entre o estilo de aprendizagem do aluno e o estilo de ensino do professor pode impactar no nível de aprendizagem do aluno (FELDER; SILVERMAN *et al.*, 1988).

Há múltiplas definições e entendimentos do que seja estilo de aprendizagem (EA). Cerqueira (2000, p. 1) diz que os EAs “(…) relacionam-se à maneira pela qual as pessoas interagem com as condições de aprendizagem, abrangendo aspectos cognitivos, afetivos, físicos e ambientais que podem favorecer o processamento de informações.”Silva (2006, p. 45) os considera um subconjunto dos estilos cognitivos, resultado de fatores hereditários, educacionais, além da personalidade e da adaptação do indivíduo às demandas do ambiente. Entretanto,



(JACOBSON, 2003 apud SCHMITT; DOMINGUES, 2016, p.364) diz que o EA de uma pessoa pode se alterar ao longo do tempo, em função da sua maturidade.

Um dos modelos amplamente utilizados para determinação de estilos de aprendizagem é o de Felder-Silverman (FELDER; SILVERMAN *et al.*, 1988). Esse modelo trabalha com quatro dimensões, a saber: Processamento, Percepção, Recepção e Entendimento da Informação. Cada uma das dimensões possui 2 categorias, com características definidas da seguinte forma:

- a) Ativo (esforço ao aprendizado, gosta de trabalhar em grupo) ou Reflexivo (aprende a pensar, prefere trabalhar sozinho ou com um ou dois parceiros);
- b) Sensitivo (concreto, prático, voltado para fatos e procedimentos) ou Intuitivo (conceitual, inovador, orientado para teorias e significados subjacentes);
- c) Visual (prefere representações visuais do material apresentado, tais como imagens, diagramas e fluxogramas) ou Verbal (prefere escrita e explicações comentadas);
- d) Sequencial (processo de pensamento linear, aprende com passos incrementais) ou Global (processo de pensamento holístico). (FELDER; SPURLIN, 2005 apud SCHMITT; DOMINGUES, 2016, p.371)

Um dos possíveis caminhos para se atingir a melhor experiência de aprendizagem para o estudante é utilizar estratégias de ensino e tipos de conteúdos educacionais que seriam mais adequados ao seu estilo de aprendizagem. Nesse sentido, Bourkhouk e El Bachari (2018) indicam um conjunto de atividades e objetos de aprendizagem que seriam mais adequados para cada uma das categorias do modelo de Felder-Silverman, conforme descrito na tabela 1.

**Tabela 1 – Sugestões de estratégias de ensino e tipos de OA para cada estilo de aprendizagem.**  
**Fonte: adaptado de (BOURKHOUK; El Bachari, 2018)**

| Estilo de Aprendizagem | Estratégia de Ensino sugerida  | Tipo de Mídia do OA  |
|------------------------|--|--|
| Ativo                  | Simulação, Resolução de Problemas, Discussão em Grupo, Brainstorming, Experimentos, Perguntas e Respostas. | Fórum de discussão, Página Wiki, Blog, Chat, E-mail, Questões de Múltipla Escolha. |
| Reflexivo              | Apresentação, Estudo de Caso.  | E-book, texto escrito.   |
| Sensitivo              | Apresentação, Leitura de Texto, Resolução de Problemas, Jogos de Simulação, Perguntas e Respostas.         | Fórum de discussão, Blog, Página Wiki, Animação, Gráfico, Figura                   |
| Intuitivo              | Discussão em Grupo, Simulação, Jogos de Papéis, Estudo de Caso, Leitura                                    | Mecanismo de Busca na Internet, Quiz, Questões de Múltipla Escolha                 |
| Visual                 | Simulação, Apresentação, Leitura de Texto  | Fórum de Discussão, Página Wiki, Gráfico, Figura, Simulação, Vídeo                 |
| Verbal                 | Grupos de Discussão, Brainstorming, Perguntas E Respostas, Resolução de Problemas                          | Gravação de Áudio, Podcast   |
| Sequencial             | Apresentação, Perguntas e Respostas  | E-book, Áudio  |
| Global                 | Jogos de papéis, Brainstorming, Estudo de Caso   | Blog, Página Wiki, Chat, E-mail, Questões de Múltipla Escolha.                     |

Todavia, para escolha da melhor abordagem de ensino para o aluno, é necessário primeiramente conseguir determinar a qual EA ele está associado. Uma das alternativas para identificação dos estilos de aprendizagem do modelo Felder-Silverman é a utilização o Índice de Estilos de Aprendizagem de Felder-Soloman (ILS) (SOLOMAN; FELDER, 2005). Trata-se de um questionário com 44 perguntas, por meio do qual se busca identificar as categorias do estilo de aprendizagem do aluno em cada uma das quatro dimensões do modelo proposto.

Dessa maneira, a teoria relacionada aos estilos de aprendizagem busca identificar as diferenças entre os estudantes no que se refere às suas especificidades no processo de ensino-aprendizagem. Conhecidas tais diferenças, o outro desafio é adequar as metodologias de ensino e conteúdos para prover a melhor experiência de acordo com as necessidades do estudante.

### **3.3 Otimização**

A otimização é um princípio implícito à análise de complexos problemas de decisão ou de alocação de recursos (LUENBERGER; YINYU, 2016). Ela está relacionada à busca da melhor solução para um problema, levando-se em conta um objetivo estabelecido e o conjunto de soluções viáveis. Dada a complexidade das questões tratadas, frequentemente busca-se simplificar a difícil relação entre as diversas variáveis do problema, considerando aquelas relações mais representativas para a qualidade da solução.

A qualidade de uma solução é mensurada a partir do objetivo estabelecido como parâmetro de medida. Tal objetivo é expresso na forma de uma função, sendo a melhor solução representada pelo conjunto de valores que façam com que a função seja maximizada ou minimizada, a depender do objetivo considerado. Faz-se necessário ainda atender restrições que correspondem a limitações relacionadas ao problema, sejam elas de natureza física, tecnológica ou não aceitáveis por motivos subjetivos (LUENBERGER; YINYU, 2016).

Na maioria das vezes é impossível, para um problema de decisão complexo, conseguir representar de maneira plena toda a complexidade de variáveis, restrições e objetivos que o envolve. Desse modo, uma formulação de otimização em particular deve ser considerada apenas uma aproximação, quando relacionada a técnicas de análise quantitativa (LUENBERGER; YINYU, 2016). Portanto, quando a modelagem de um problema envolve otimização, é preciso um profundo entendimento do mesmo, de modo a se extrair os elementos essenciais para sua resolução.

Quando o processo de otimização compreende apenas uma única função objetivo, fala-se em otimização mono-objetivo. Ela consiste na busca de um único ponto, um valor no qual a função considerada é minimizada ou maximizada. Por outro lado, a otimização multiobjetivo considera mais de uma função objetivo. Nesse caso, tem-se um conjunto de soluções ótimas de um problema (VIRA; HAIMES, 1983).

Os problemas de decisão com um número contável de alternativas são chamados discretos. Caso contrário, são chamados contínuos (EHRGOTT, 2006). Nas duas subseções seguintes são apresentados, respectivamente, maiores detalhes relacionados à otimização mono-objetivo e multiobjetivo.


### 3.3.1 Otimização Mono-objetivo

O problema de otimização mono-objetivo busca um valor para minimizar a função objetivo de um problema. Sua modelagem pode ser definida da seguinte maneira, proposta por (GOLDBARG; LUNA, 2005):

$$\begin{aligned} &\min f(x) \\ &\text{sujeito a: } \begin{cases} g_i(x) \leq 0 & \forall i = 1, \dots, p \\ h_j(x) = 0 & \forall j = 1, \dots, q \end{cases} \end{aligned} \quad (3.1)$$

Na modelagem acima,  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é a função objetivo que se deseja minimizar,  $g : \mathbb{R}^n \rightarrow \mathbb{R}$  são as  $p$  restrições de desigualdade e  $h : \mathbb{R}^n \rightarrow \mathbb{R}$  são as  $q$  restrições de igualdade. Tem-se o conjunto de soluções viáveis  $\mathcal{F} = \{x \in \mathbb{R}^n : g_i(x) \leq 0 \text{ e } h_j(x) = 0\}$ . Busca-se a solução  $x^* \in \mathcal{F}$  que possui o menor valor em  $f(x)$ .

Outros dois conceitos referentes à otimização são as soluções ótimas locais e ótima global. Uma solução  $x^* \in \mathcal{F}$  é considerada ótima global somente se não existir outra solução  $x \in \mathcal{F}$ , na qual  $x \neq x^*$  e  $f(x) < f(x^*)$ . Por sua vez, uma solução  $x'$  é chamada ótima local se, para um dado subconjunto de soluções  $\mathcal{F}' \subset \mathcal{F}$ , não existir nenhuma outra solução  $x \in \mathcal{F}'$ , sendo  $x \neq x'$ , com  $f(x) < f(x')$ . A figura 1 ilustra esses dois conceitos.



**Figura 1 – Dada uma função objetivo para minimização são apresentadas soluções ótimas locais e a solução ótima global para o problema. Fonte: (MARAVILHA, 2011)**

### 3.3.2 Otimização Multiobjetivo


Em diversas áreas engenharia e campos das ciências, não é raro que os problemas de otimização possuam vários objetivos conflitantes entre si (SINDHYA; MIETTINEN; DEB, 2013). Nessas condições, buscar soluções ótimas a partir de um único objetivo pode levar a resultados impraticáveis para os demais objetivos (AHMADI *et al.*, 2013). Ao se lidar com objetivos tais como custo e desempenho, busca-se na verdade um conjunto de soluções que representem diferentes tipos de escolhas entre os objetivos, possibilitando ao tomador de decisão selecionar a solução a ser utilizada, dentro do contexto no qual o problema está inserido. Isto

posto, através da equação 3.2 definir o Problema de Otimização Multiobjetivo, conforme exposto por (GUTJAHR; PICHLER, 2016), considerando que todos os objetivos são de minimização:

$$\min(f_1(\mathbf{x}), \dots, f_m(\mathbf{x})), \mathbf{x} \in \mathcal{X} \quad (3.2)$$

As  $m$  funções objetivo do problema são definidas por  $f_j : \mathcal{X} \rightarrow \mathbb{R} (j = 1, \dots, m)$ , sendo  $m \geq 2$ . Tem-se também que  $\mathbf{x}$  é o vetor de variáveis de decisão no espaço de decisões  $\mathcal{X}$  do problema, o qual está sujeito a um conjunto de  $i$  restrições  $g_i(\mathbf{x}) = b_i$ . Tais restrições limitam as variáveis de decisão a um subconjunto  $\mathcal{F}$ , chamado de região factível, a qual contém as soluções de fato viáveis (KONAK; COIT; SMITH, 2006).

A figura 2 ilustra o mapeamento de soluções. O mapeamento do espaço de decisões  $\mathcal{X}$  no espaço objetivo (conjunto-imagem)  $\mathcal{Y}$  é realizado pela função  $\mathbf{f}(\mathbf{x})$ , neste exemplo composta por dois objetivos. A região de soluções viáveis é dada por  $\mathcal{F}$ . Cada solução  $x_i$  tem seu respectivo ponto  $y_i$  correspondente no espaço objetivo. Apesar da solução  $x_4$  resultar em um ponto  $y_4$  aparentemente melhor que os obtidos pelas soluções  $x_1$  e  $x_2$ , ela não pertence ao conjunto de soluções viáveis ( $x_4 \notin \mathcal{F}$ ).




**Figura 2 – Mapeamento de soluções em um problema de otimização combinatória multiobjetivo.**  
Fonte:(ASSIS, 2013)

Já a comparação entre as soluções em um problema multiobjetivo se dá pela relação de dominância, conforme definição 3.3.1, adaptada de (KONAK; COIT; SMITH, 2006):

**Definição 3.3.1 (Dominância).** Um vetor de soluções  $x_1 \in \mathcal{X}$  domina outro vetor  $x_2 \in \mathcal{X}$ , com  $x_2 \neq x_1$ , se e somente se  $f_j(x_1) \leq f_j(x_2)$ , para  $j = 1, \dots, m$ , e  $f_j(x_1) < f_j(x_2)$  em pelo menos uma das  $j$  funções objetivos. Essa relação é denotada por  $x_1 \prec x_2$ .

A figura 3 apresenta um exemplo gráfico da relação de dominância. Dadas duas funções objetivo para minimização  $f_1$  e  $f_2$  e um ponto no espaço objetivo obtido por uma solução  $\mathbf{y}'$ . O espaço objetivo é dividido em quatro áreas a partir do ponto gerado por  $\mathbf{y}'$ , onde pode ser observado a relação de dominância entre esta solução e as demais (ZITZLER, 1999).

Em grande parte das situações reais, os objetivos são conflitantes. Não haverá, portanto, uma única solução que minimize todos os  $j$  objetivos ao mesmo tempo (AHMADI



**Figura 3 – Relação de dominância.** Fonte:(ASSIS, 2013)


*et al.*, 2013). Consequentemente, não há uma única solução que domine todas as outras. Na verdade, busca-se um conjunto de soluções que otimize o vetor de decisões do problema. Nesse contexto, apresenta-se o conceito de solução eficiente e conjunto de Pareto, conforme definição 3.3.2 (GUTJAHR; PICHLER, 2016):

**Definição 3.3.2 (Solução Eficiente).** Uma solução  $x_1 \in \mathcal{X}$  é chamada eficiente, ou Pareto-ótima, se não existir nenhuma solução viável  $x_2 \in \mathcal{X}$ , com  $x_2 \neq x_1$ , tal que  $x_2$  domine  $x_1$ .

O conjunto de soluções eficientes em  $\mathcal{X}$  é denominado conjunto Pareto-ótimo. Por sua vez, a imagem do conjunto Pareto-ótimo, isto é, os pontos no espaço de objetivos correspondentes aos valores das funções objetivos em cada solução, é chamada de Fronteira Pareto-ótima (KONAK; COIT; SMITH, 2006).

O desafio maior de um problema de otimização multiobjetivo consiste em encontrar, portanto, o conjunto Pareto-ótimo. Todavia, esta não é uma tarefa fácil de se realizar, sobretudo em problemas da classe *NP*-difícil. Isto posto, o que se procura fazer é obter um conjunto de soluções o qual retrate da forma mais próxima possível a fronteira Pareto-ótima, no que diz respeito à qualidade e à diversidade das soluções.

A figura 4 ilustra a comparação entre fronteira de Pareto-ótima e uma fronteira de Pareto obtida. Os pontos preenchidos representam a fronteira Pareto-Ótima. Já os pontos não preenchidos formam uma aproximação à fronteira Pareto-Ótima. Este conjunto aproximado é formado por soluções não dominadas entre si, porém existem pontos que não fazem parte da fronteira Pareto-Ótima.



**Figura 4 – Exemplo de Fronteira de Pareto-Ótima e Fronteira de Pareto aproximada.**  
**Fonte: (ASSIS, 2013)**

Nesse contexto, Konak, Coit e Smith (2006) elencam três aspectos, os quais embora conflitantes, devem ser considerados na obtenção da fronteira de Pareto em um processo de otimização dessa natureza:

- a fronteira de Pareto obtida deve ser a mais próxima possível da fronteira Pareto-ótima, preferencialmente um subconjunto desta;
- suas soluções devem possuir a maior diversidade possível, de modo a cobrir a extensão da fronteira Pareto-ótima de maneira uniforme, apresentando ao tomador de decisão uma perspectiva real das possibilidades de escolha;
- as soluções devem contemplar toda a extensão da fronteira de Pareto-ótima, através de uma busca por soluções inclusive nos extremos do espaço das funções objetivos.

## 4 O PROBLEMA DE RECOMENDAÇÃO DE OBJETOS DE APRENDIZAGEM MULTIOBJETIVO

O presente capítulo tem por finalidade apresentar o Problema de Recomendação de Objetos de Aprendizagem Multiobjetivo. Na seção 4.1 se apresenta um pequeno exemplo do mesmo, sendo que na seção 4.2 se encontra a sua modelagem. Na seção 4.3 é apresentada a arquitetura do sistema de recomendação e a seção 4.4, por sua vez, detalha o modelo que calcula o custo dos objetos de aprendizagem (OAs).

### 4.1 Exemplo de aplicação

Antes de apresentar a modelagem do problema, convém apresentar um exemplo simples para melhor compreensão. Para tanto, imagine-se uma seção de aprendizagem de um determinado curso, composta pelos conceitos  $a$ ,  $b$ ,  $c$ ,  $d$ , e  $e$ . Nesse exemplo, o *design* instrucional dessa seção determina que o conceito  $c$  é considerado um pré-requisito para o conceito  $d$ , o que significa dizer que é necessário apresentar  $c$  antes de  $d$ , para que o aluno tenha correta compreensão do que está sendo ensinado.

Supondo haver um repositório de OAs que será utilizado como fonte de recursos para o curso supramencionado, no qual os conceitos que cada OA cobre está indicado conforme a seguir:  $OA_1 = \{b, c\}$ ,  $OA_2 = \{e\}$ ,  $OA_3 = \{a, d\}$ ,  $OA_4 = \{d, e\}$ ,  $OA_5 = \{a, c\}$ ,  $OA_6 = \{b\}$ , sendo o custo de cada OA calculado em 5, 3, 8, 7, 9 e 5 respectivamente, para um determinado estudante. Considerando que esse estudante queira estudar a seção de aprendizagem supramencionada, uma possível solução seria  $S_1 = \{OA_1, OA_2, OA_3\}$ , que teria custo 16.

Importante notar ainda com relação a  $S_1$  que o conjunto de OAs não obedece necessariamente a sequência de apresentação dos conceitos da seção. O conceito  $a$  é coberto pelo  $OA_3$  e os conceitos  $b$  e  $c$  pelo  $OA_1$ , porém o conceito  $d$  é coberto também pelo mesmo  $OA_3$  que cobriu  $a$ . Pressupõe-se que os OAs estão organizados de maneira que seja possível ao aluno, através do sistema de recomendação, identificar qual parte do OA se refere a cada conceito, de maneira semelhante às seções de uma página wiki. Desse modo, no exemplo acima, o aluno estuda o conceito  $a$  presente no  $OA_3$ , em seguida acessa o  $OA_1$  para estudar  $b$  e  $c$ , passando novamente a acessar  $OA_3$  naquilo que estiver relacionado ao conceito  $d$ .

A solução  $S_2 = \{OA_3, OA_4, OA_6\}$  por sua vez, não seria válida. Isso porque ela cobre o conceito  $d$  mas não cobre o conceito  $c$ , o qual é pré-requisito para  $d$ . A solução  $S_3 = \{OA_5, OA_6\}$  de custo 13 seria válida porque, embora não cubra dois dos conceitos projetados para a seção de aprendizagem, respeita a relação de dependência estabelecida pelo *design* instrucional.

A ideia de haver soluções que não cubram todos os conceitos é para dar a possibilidade de escolha dentre soluções de diferentes coberturas por um curso menos completo mas que possa estar mais próximo dos objetivos e da realidade do aluno. Por exemplo, muitas vezes o estudante pode ter um tempo limitado para fazer um curso completo, então passa a ter a possibilidade de fazer um curso que não está completo mas possui um conjunto mínimo de conceitos cobertos que é adequado à sua disponibilidade.

Todavia, devido à limitação de conhecimento metacognitivo que o aluno possui, não é adequado que ele próprio escolha dentre todas as soluções qual é aquela que melhor lhe atenderá. Diante disso, na ausência de um tutor que auxilie o aluno nesse processo de escolha, próprio sistema de recomendação faz a seleção. Isso ocorre a partir da solução que apresente a menor proporção do custo em relação ao número de conceitos cobertos.

Ainda com relação a  $S_2$ , é importante notar o seguinte: caso não houvesse a relação de pré-requisito especificada e a solução fosse válida, o conceito  $d$  estaria coberto por dois OAs na mesma solução, isto é,  $OA_3$  e  $OA_4$ . Nesse caso, o sistema de recomendação definiria qual OA seria utilizado pelo aluno, de acordo com o OA que apresentasse menor custo.

## 4.2 Modelagem matemática

Uma vez exposto um exemplo, a seguir é apresentado o Problema de Recomendação de Objetos de Aprendizagem Multiobjetivo, com sua respectiva modelagem. Os conceitos previstos para uma determinada seção de aprendizagem são previstos no *design* instrucional. Esses conceitos estão organizados em uma sequência lógica de aprendizagem, sendo que alguns conceitos dependem de outros, isto é, o aprendizado de um conceito é um pré-requisito para o aprendizado de outro. Outros conceitos, por sua vez, não necessariamente possuem essa dependência.

A dependência entre os conceitos é representada pelo grafo acíclico direcionado  $G = (V, A)$ , em que  $V = \{v_0, v_1, v_2, \dots, v_m\}$  é o conjunto de vértices, e cada vértice representa um dos  $m$  conceitos da seção de aprendizagem. A aresta  $(v_i, v_j)$  indica que o conceito  $c_i$  precisa ser aprendido antes do conceito  $c_j$ , aqui denotado por  $c_i \longrightarrow c_j$ , ou ainda que  $c_j$  depende de  $c_i$ .

Os conceitos podem ser estudados a partir de objetos de aprendizagem. Todos os  $n$  OAs disponíveis estão armazenados em um repositório  $R = \{OA_1, OA_2, \dots, OA_n\}$ . Cada OA cobre um determinado número não-nulo de conceitos. Adota-se aqui a notação  $OA_i \rightarrow \{c_1, c_2, c_3\}$ , indicando que o Objeto de Aprendizagem  $i$  cobre os conceitos  $c_1$ ,  $c_2$  e  $c_3$ .

A cada objeto de aprendizagem está associado um custo, que representa o quão distante aquele OA está em relação às preferências, expectativas e necessidades de aprendizagem apresentada por um estudante. Esse custo pode ser determinado de diferentes maneiras, podendo utilizar os atributos do próprio OA, o perfil do usuário demandante do aprendizado, assim como outras informações de contexto. No problema ora abordado, o custo é determinado pela relação entre o estilo de aprendizagem do aluno e o tipo de mídia do OA, bem como pelo modo como alunos com mesmo estilo de aprendizagem avaliaram tal OA. O cálculo desse custo se encontra detalhado na seção 4.4.

Desse modo, seja uma seção de aprendizagem  $W = \{c_1, c_2, \dots, c_m\}$ , composto por um conjunto de  $m$  conceitos. No problema ora proposto, busca-se recomendar ao estudante um conjunto de objetos de aprendizagem que cubram conceitos de  $W$ . Todavia, na abordagem proposta, não necessariamente todos os conceitos previstos precisam ser cobertos. Na verdade, para obtenção de uma solução, trabalha-se com dois objetivos conflitantes: a quantidade de



conceitos cobertos e o custo da solução, dado pela soma do custo de todos os OAs que fazem parte da solução.

Uma solução consiste em recomendar um conjunto de objetos de aprendizagem  $\gamma = \{OA_i, OA_j, \dots, OA_z\}$  que cubra pelo menos um dos conceitos da seção de aprendizagem almejada, respeitadas as relações de dependência entre tais conceitos. Busca-se obter as soluções que possuam a maior cobertura e o menor custo possíveis. Naturalmente, haverá não apenas uma solução, mas um conjunto cujas soluções aumentam de custo à medida que cobrem uma quantidade maior de conceitos. Trata-se, portanto, de uma abordagem multiobjetivo de um problema no âmbito educacional que é computacionalmente semelhante ao Problema de Cobertura de Conjuntos (BEASLEY; CHU, 1996), com a variação de que a cobertura não é uma restrição a ser obedecida, mas passa a ser tratada como um objetivo a ser maximizado.

Assim sendo, a variável de decisão está relacionada a cada um dos  $i$  Objetos de Aprendizagem considerados, assumindo valor 1 se um determinado OA faz parte da solução, ou valor 0 caso contrário, conforme expressão 4.1 abaixo:

$$x_i = \begin{cases} 1 & , \text{ se } OA_i \in \gamma, \\ 0 & , \text{ caso contrário.} \end{cases} \quad (4.1)$$

Um dos objetivos é maximizar a cobertura, dada pela soma de cada um dos  $m$  conceitos  $c$  da seção de aprendizagem que estiverem cobertos por algum Objeto de Aprendizagem que estiver na solução, conforme a expressão 4.3. O valor de  $c_j$  é definido conforme expressão 4.2 abaixo:

$$c_j = \begin{cases} 1 & , \text{ se } \exists OA \in \gamma \mid OA \multimap c_j, \\ 0 & , \text{ caso contrário.} \end{cases} \quad (4.2)$$

$$Max f(c) = \sum_{j=1}^m c_j \quad (4.3)$$

O outro objetivo é minimizar o custo  $\ell$  da solução, conforme a expressão 4.4:

$$Min f(\ell) = \sum_{i=1}^n \ell_i x_i \quad (4.4)$$

As seguintes restrições devem ser satisfeitas:

Se um dado OA cobrir um conceito que dependa de outro, esse outro conceito também deve estar coberto na mesma solução:

$$\forall c_i \in W \mid c_i \mapsto c_j, \text{ se } \exists OA \in \gamma \mid OA \multimap c_j, \text{ então } \exists OA \in \gamma \mid OA \multimap c_i \quad (4.5)$$

A solução nula, ou seja, que não cubra nenhum conceito, não é considerada:

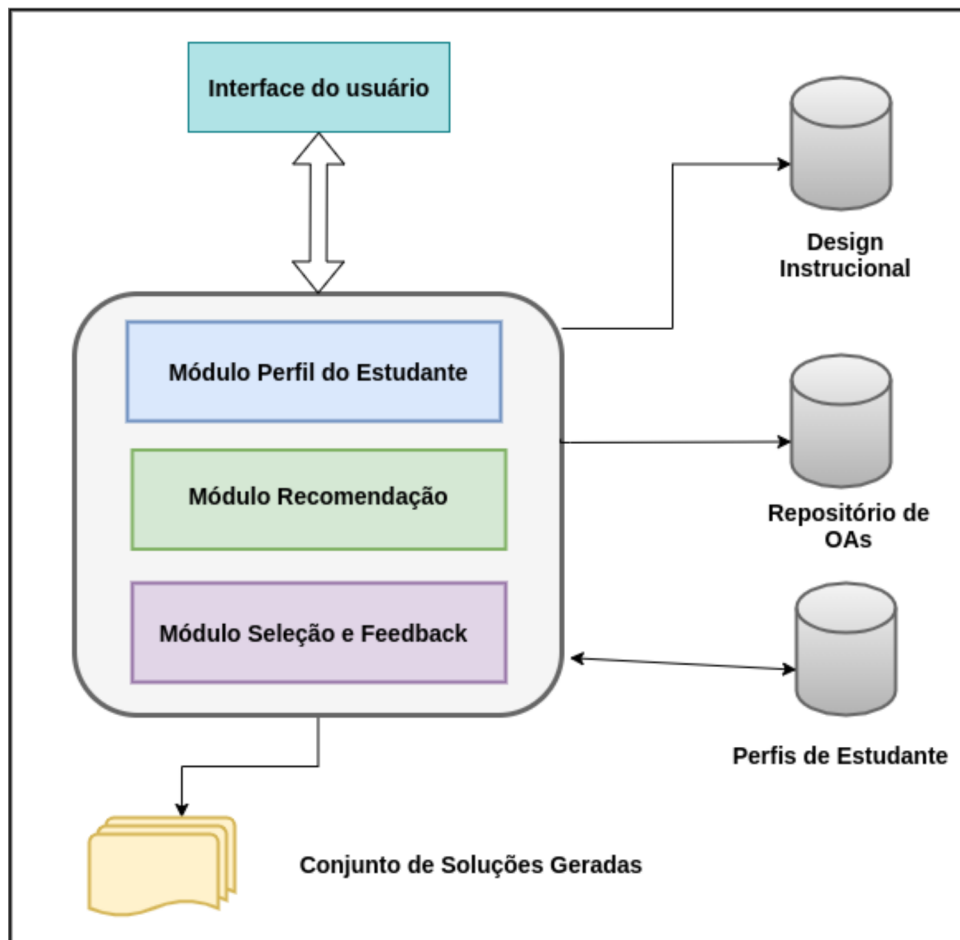
$$\sum_{j=1}^m c_j > 0 \quad (4.6)$$

Restrição de integralidade da variável de decisão:

$$x_i \in \{0, 1\}, \quad i = 1, \dots, n \quad (4.7)$$

### 4.3 O Sistema de recomendação multiobjetivo

O Sistema de Recomendação no qual está inserida a abordagem proposta é composto basicamente por três módulos, conforme explicitado a seguir.



**Figura 5 – Estrutura do Sistema de Recomendação Proposto. Fonte: próprio autor**

O primeiro módulo é o de Perfil do Estudante, responsável por determinar o estilo de aprendizagem do aluno que pretende estudar a seção de aprendizagem a partir do sistema proposto. A determinação do estilo de aprendizagem é utilizada para determinar quais os tipos de OAs são mais adequados para o estudante, conforme indicado na seção 3.2.

O segundo módulo é o de Recomendação propriamente dito, o qual está dividido em diferentes etapas, conforme descrito a seguir:

- Consulta ao *design* instrucional, com o intuito de obter quais os conceitos compõem a seção de aprendizagem, bem como verificar as dependências existentes entre eles;
- Seleção de OAs: busca-se então no repositório de OAs aqueles que cobrem pelo menos um dos conceitos previstos, ou seja, aqueles os quais podem eventualmente ser recomendados;

- Atribuição de custo de cada um dos OAs selecionados na etapa anterior. Tal custo é calculado a partir de quão adequado é o tipo de mídia do OA (consultado a partir dos metadados do OA) para o estilo de aprendizagem do aluno (determinado no módulo Perfil de Estudante). A avaliação que outros usuários com mesmo perfil já possam ter feito em cada um dos OAs também engloba o cálculo do custo. Esse cálculo se encontra pormenorizado na seção 4.4.
- Geração dos conjuntos de OAs com o auxílio do NSGA II, a partir do vetor de custos de OAs para o estudante gerado na etapa anterior. O cálculo de qualidade das soluções geradas se dá conforme as equações 4.3 e 4.4 explicadas na seção anterior.

O terceiro módulo do sistema é o módulo de Seleção e *Feedback*, por meio do qual o sistema escolhe para o estudante, dentre as distintas soluções geradas pelo módulo de recomendação, aquela que será utilizada. A escolha se dá pela solução que apresente menor proporção do custo em relação ao número de conceitos cobertos. À medida que o estudante acessa e utiliza os OAs daquela solução, o sistema solicita a ele que faça também a avaliação do OA. Essa avaliação é utilizada para calcular o custo do OA para futuros alunos que venham a utilizar o sistema.

A figura 5 apresenta a estrutura para o sistema de recomendação proposto. O estudante acessa o sistema por uma interface responsável por estabelecer a comunicação com o sistema. Por intermédio dela, o módulo responsável por determinar o perfil do aluno obtém as informações do estudante, que o adiciona ao conjunto de perfis de estudantes já existentes. Também é através da interface do usuário que o conjunto de soluções geradas são disponibilizadas para escolha do estudante.

#### 4.4 Cálculo do custo de um objeto de aprendizagem para cada aluno

Seja uma matriz  $n \times m$ , a qual representará o custo de cada um dos  $n$  alunos para os  $m$  objetos de aprendizagem disponíveis para cobrir conceitos de um determinado curso inteiro ou mesmo uma seção de aprendizagem. Para tanto, busca-se determinar o custo  $c$  de cada estudante  $e$  para o OA  $j$ .

O cálculo do custo se dá em duas etapas, chamados custo inicial  $li$  e custo final  $lf$ . A primeira etapa se baseia na relação entre o estilo de aprendizagem (EA) do aluno e o tipo de mídia do OA, conforme indicado por (BOURKOUKOU; El Bachari, 2018) e explicado na seção 3.2. O cálculo se dá conforme demonstrado na equação 4.8.

Avalia-se o tipo do OA em relação a cada uma das 4 dimensões do modelo Felder-Silverman (FELDER; SILVERMAN *et al.*, 1988) na qual o estudante foi categorizado, conforme explicado na seção 3.2. Para cada dimensão do estilo de aprendizagem, é verificado se o tipo de mídia do OA considerado se mostra adequado à categoria em que o estudante  $e$  foi inserido. Caso positivo,  $p$  assume valor 20 e se tem um decréscimo no custo total do OA em relação àquele estudante. Caso contrário,  $p$  assume valor 0 e o custo total não é reduzido.

Desse modo, na primeira fase o custo máximo de um OA seria 100 - quando ele não se mostra propício ao aluno em nenhuma das dimensões do EA - e no mínimo 20, quando há

sua adequabilidade ao estudante nas 4 dimensões do modelo, havendo um decréscimo de 80 unidades em relação ao custo máximo estabelecido.

$$li(OA_e) = 100 - \sum_{i=1}^4 p_i^e, \quad p \in \{0, 20\} \quad (4.8)$$

$$p_i^e = \begin{cases} 20 & , \text{ se o tipo do OA é adequado à categoria de } e \text{ na dimensão } i, \\ 0 & , \text{ caso contrário.} \end{cases} \quad (4.9)$$

A segunda etapa, para determinação do custo final  $lf$  de um OA em relação ao estudante, dá-se pela aplicação da filtragem colaborativa. Nessa fase, são considerados os  $m'$  usuários com estilo de aprendizagem semelhante ao do estudante  $e$  em questão, os quais já tenham avaliado o OA cujo custo está se calculando, conforme estrutura proposta na figura 5 da seção 4.3. São considerados apenas os alunos que foram categorizados da mesma maneira em cada uma das 4 dimensões do estilo de aprendizagem de Felder-Silverman.

A avaliação do OA pelos alunos se dá a partir de uma nota  $r$  atribuída pelos usuários, a qual pode variar de 1 a 100, sendo 100 uma avaliação muito positiva do OA e 1 uma avaliação muito negativa. Assim, o custo de um OA para um estudante que já avaliou esse OA é o valor resultante de  $100-r$ . Isso faz com que, quanto melhor seja a avaliação, menor o custo do OA relacionado ao aluno que o avaliou.

A equação 4.10 mostra como se dá o cálculo do custo final  $cf$  de um OA para um estudante  $e$ . É considerada a média do custo de cada um dos  $m'$  estudantes de mesmo EA que  $e$ , acrescida inclusive do custo inicial  $li$  do próprio estudante obtida na primeira etapa acima descrita. Caso ainda não haja nenhum outro aluno com mesmo estilo de aprendizagem que tenha avaliado o OA, apenas o custo  $li$  da etapa anterior é considerado para obtenção do custo final.

$$lf(OA_e) = \frac{li(OA_e) + \sum_{i=1}^{m'} 100 - r_i}{m' + 1}, \quad r \in \{1, \dots, 100\}, \quad m' > 0 \quad (4.10)$$

## 5 METODOLOGIA

O presente capítulo apresenta a metodologia experimental aplicada para realização dos testes relacionados ao problema proposto. Ele se encontra dividido em duas seções. A primeira consiste nos testes iniciais que foram realizados. A segunda seção descreve novos testes, com parâmetros que foram modificados a partir da observação dos resultados obtidos nos testes anteriormente executados.

### 5.1 Testes preliminares

As instâncias de problema utilizadas foram geradas artificialmente, conforme a tabela 2, na qual são indicados um nome indicador de cada instância. São indicados ainda, quantidade de OAs, probabilidade de cobertura, quantidade de conceitos e de dependências.

**Tabela 2 – Características das instâncias geradas para os testes preliminares**

| Instância | OAs  | P Cobertura | Conceitos | Dependências |
|-----------|------|-------------|-----------|--------------|
| F3        | 1000 | 0,05        | 200       | 10           |
| F2        | 1000 | 0,02        | 200       | 10           |
| R3        | 100  | 0,2         | 20        | 2            |

Duas delas (F2 e F3) são criadas possuindo um universo de 1000 Objetos de Aprendizagem e 200 conceitos, os quais foram estabelecidos tendo como referência o *benchmark* OR-Library, especificamente a sua instância 4.10<sup>1</sup>, a qual trata do Problema de Cobertura de Conjuntos de 200 linhas por 1000 colunas, sendo utilizada também no trabalho de (JÚNIOR; DORÇA, 2018). Há ainda uma instância de dimensões menores, com 100 OAs e 20 conceitos, denominada R3.

O vetor de custos dos OAs do estudante foi gerado aleatoriamente entre os valores de 1 a 100. A matriz de cobertura da instância F2 foi gerada com cada OA tendo uma probabilidade de 0,02 de cobrir cada conteúdo. Na instância F3, por sua vez, essa probabilidade de cobertura é de 0,05. Em ambas foram criadas 10 dependências distintas entre conceitos, sendo os conteúdos também escolhidos aleatoriamente para compor as dependências.

Portanto, a diferença entre F2 e F3 é que a matriz de cobertura de F3 é mais densa que a matriz de cobertura de F2, uma vez que nessa um mesmo OA cobre, em média, menos conceitos que naquela. Em R3, a probabilidade de cobertura é 0,2.

O problema foi implementado no *framework* MOEA (*Multiobjective Evolutionary Algorithm*) (MOEA, 2020), que possui um conjunto de bibliotecas em Java para desenvolvimento e realização de experimentos com algoritmos evolucionários multiobjetivo. Para resolução, foi utilizado o algoritmo genético NSGA-II (DEB *et al.*, 2000), um dos algoritmos evolucionários mais utilizados no campo da otimização. Os parâmetros padrões do MOEA são com população inicial de 100 indivíduos e 10000 gerações do algoritmo, sendo utilizado um método randômico para geração da população inicial.

<sup>1</sup> A referida instância está disponível em <http://people.brunel.ac.uk/~mastjjb/jeb/orlib/files/scp410.txt>

No método de inicialização padrão do MOEA, são gerados valores aleatórios para cada uma das variáveis de decisão. No problema em questão, cada OA é uma variável de decisão, assumindo apenas dois possíveis valores: 1 se o OA está na solução ou 0 caso contrário. Portanto, cada OA é aleatoriamente escolhido para compor uma solução. Isso gera diferentes combinações de soluções onde em cada uma delas, em média, metade dos OAs estão presentes, haja vista que a probabilidade de ocorrência dos valores 0 ou 1 é igual.

Além do método de geração da população inicial do próprio MOEA, foi criado um método aleatório baseado na cobertura de cada solução, concebido conforme o algoritmo 1. Seja uma seção de aprendizagem  $W$  com  $n$  conceitos e uma população inicial  $PI$  de  $m$  indivíduos que se queira gerar. Busca-se criar uma população com indivíduos que possuam as mais diversas quantidades de conceitos cobertos.

---

**Algorithm 1** Algoritmo de Geração da População Inicial

---

**Require:**  $m$  (Tamanho da População),  $N$ (conceitos da seção),  $D$ (dependências de conceitos),  $R$ (Repositório de OAs)

```

1:  $PI \leftarrow \emptyset$ ;
2:  $n' \leftarrow \text{Total Conceitos Não Dependentes } (N, D)$ ;
3:  $i \leftarrow 0$ ;
4: repeat
5:    $i \leftarrow i + 1$ ;
6:    $P \leftarrow \emptyset$ ;
7:    $t_p \leftarrow \text{Tamanho Cobertura da Solução}(n')$ ;
8:    $j \leftarrow 0$ ;
9:    $c[] \leftarrow 0$ ;
10:  while  $j \leq t_p$  do
11:     $c[] \leftarrow \text{Escolhe Conceito } (c[], N)$ ;
12:     $S[] \leftarrow \text{Seleciona OA de Cobertura } (c[j], R)$ ;
13:     $j \leftarrow j + 1$ ;
14:  end while
15:   $P \leftarrow \text{Adiciona Solução}(S[])$ ;
16:   $PI \leftarrow PI \cup P$ ;
17: until  $i \leq m$ ;
18: return  $PI$ ;

```

---

Nesse sentido, é delimitado para cada indivíduo a quantidade de conceitos que ele deve cobrir, conforme a seguir. Tal valor representa a quantidade de conceitos que não são dependentes. Desse modo, tem-se  $n'$  conceitos que não dependem de outros conceitos, conforme linha 2.

Para cada indivíduo, é gerado um número aleatório entre 1 e  $n'$ , aqui denominado  $t_p$ , que representa a cobertura (quantidade de conceitos) da solução que aquele indivíduo terá, indicado na linha 7. Em seguida, são selecionados randomicamente  $t_p$  vezes os conceitos que comporão aquela solução, o que é executado no laço das linhas 10 a 14.

Para cada conceito selecionado na linha 11, verifica-se quais OAs o cobrem, sendo então selecionado de forma aleatória um deles para compor a solução (linha 12). Caso o OA já

esteja na solução por estar cobrindo outro conceito já selecionado, nada é acrescentado porque o OA já está na solução. Assim que estiverem selecionados os OAs para cobrir todos os conceitos daquela solução, eles se tornam uma solução (linha 15) e são adicionados como um indivíduo da população inicial (linha 16). Tal procedimento é repetido para cada um dos  $m$  indivíduos da população, conforme indicado das linhas 4 a 17.

Com relação a esse algoritmo, é importante destacar que um mesmo conceito pode ser escolhido em iterações diferentes dentro da mesma solução, podendo ainda ser coberto por distintos OAs, uma vez que cada OA também é selecionado aleatoriamente dentre todos os OAs que cobrem aquele conceito. Além disso, mais conceitos que o estabelecido em  $t_P$  podem ser cobertos, haja vista que os OAs que são aleatoriamente selecionados podem também cobrir outros conceitos além daqueles para o qual foram selecionados.

## 5.2 Testes com novos parâmetros

A partir dos resultados obtidos nos testes preliminares, foram realizados novos testes, com algumas alterações na configuração das instâncias, assim como a proposição de duas novas abordagens para criação da população inicial, conforme descrito a seguir.

Tratando-se das instâncias de problema, foram propostas duas novas instâncias as quais assim como as instâncias F2 e F3, também possuem um universo de 1000 OAs e 200 conceitos, além de apresentarem matrizes de cobertura de diferentes densidades. No entanto, nesse novo problema são propostos um *design* instrucional da seção de aprendizagem com o dobro de dependências entre conceitos em relação a F2 e F3, conforme demonstrado na tabela 3. O número de dependências maior é mais condizente com as situações reais no processo de ensino-aprendizagem, nas quais na maioria das vezes um determinado conceito exige um conhecimento prévio relacionado a um outro conceito. A instância utilizada anteriormente (F3) também é utilizada para avaliações e comparações dos resultados em relação aos obtidos nas novas instâncias.

**Tabela 3 – Características das instâncias geradas para os novos testes**

| Instância | OAs  | P Cobertura | Conteúdos | Dependências |
|-----------|------|-------------|-----------|--------------|
| G2        | 1000 | 0,02        | 200       | 20           |
| G3        | 1000 | 0,05        | 200       | 20           |
| F3        | 1000 | 0,05        | 200       | 10           |

Com relação aos algoritmos de inicialização da população, foi proposta uma nova variação do algoritmo 1, na qual são selecionados apenas conceitos que não dependem de outros. Na versão desse algoritmo nos testes preliminares, um conceito poderia ser selecionado para compor uma solução sem que aquele conceito do qual ele depende estivesse na mesma solução inicial. Desse modo, procura-se reduzir o número de violações de restrições em cada solução gerada.

O algoritmo 2 detalha essa nova abordagem. Note na linha 2 que  $n$  recebe o total de conceitos não-dependentes de outros, conforme *design* instrucional do curso. Nessa faixa, cujo

valor máximo possível é a quantidade de conceitos não-dependentes, é que se seleciona um valor aleatório, que será a cobertura mínima da solução, conforme executado na linha 7. Ademais, na linha 11 ao se escolher um novo conceito, verifica-se se o mesmo já fora escolhido para aquela solução, algo que não era realizado na primeira versão da abordagem nos testes preliminares, apresentada no algoritmo 1.

Na linha 12 se seleciona aleatoriamente um determinado OA para cobrir o novo conceito escolhido na linha anterior. É importante notar que, ao se selecionar randomicamente um determinado OA para cobrir um conceito, tal OA pode cobrir também outros conceitos, inclusive que não tenham sido selecionados previamente nem sejam selecionados posteriormente. Desse modo, o que se tem é a garantia de que serão cobertos no mínimo - e não exatamente - o número  $t_p$  de conceitos aleatoriamente definidos para aquela solução.

---

**Algorithm 2** Algoritmo de Geração da População Inicial Modificado

---

**Require:**  $m$  (Tamanho da População),  $N$ (conceitos do curso),  $R$ (repositório dos OAs)

---

```

1:  $PI \leftarrow \emptyset$ ;
2:  $n' \leftarrow$  Total Conceitos Não Dependentes ( $N, D$ );
3:  $i \leftarrow 0$ ;
4: repeat
5:    $i \leftarrow i + 1$ ;
6:    $P \leftarrow \emptyset$ ;
7:    $t_p \leftarrow$  Tamanho Aleatório de Cobertura da Solução( $n$ );
8:    $j \leftarrow 0$ ;
9:    $c[] \leftarrow 0$ ;
10:  while  $j \leq t_p$  do
11:     $c[] \leftarrow$  Escolhe Novo Conceito Não-dependente( $N, c[]$ );
12:     $S[] \leftarrow$  Seleção Aleatória de OA ( $c[j], R$ );
13:     $j \leftarrow j + 1$ ;
14:  end while
15:   $P \leftarrow$  Adiciona Solução( $S[]$ );
16:   $PI \leftarrow PI \cup P$ ;
17: until  $i \leq m$ ;
18: return  $PI$ ;
```

---

O outro algoritmo implementado utiliza a estratégia de selecionar aleatoriamente um conjunto de OAs para compor a solução, independentemente de quais conceitos eventualmente sejam cobertos. É uma estratégia similar ao modo de inicialização randômica do *framework* MOEA, que trabalha diretamente com valores das variáveis de decisão, que no caso do problema abordado estão relacionados à presença ou não de cada OA na solução. Todavia, na inicialização do MOEA cerca de metade de todos os OAs do repositório, em média, estavam presentes em cada solução. Na abordagem ora proposta, o número de OAs em cada solução é bem menor, conforme indicado no algoritmo 3, detalhado a seguir.

A partir do número total de OAs do repositório (linha 2), é determinado o número máximo  $n'$  de OAs que um indivíduo poderá ter (linha 3). Esse cálculo é determinado pela décima parte do total de OAs, arredondado para o número inteiro mais próximo quando o referido



valor é fracionado. Em seguida, para cada indivíduo da população é sorteado um valor entre 1 e  $n'$ , o qual representa a quantidade  $t_P$  de OAs selecionados que aquele indivíduo terá (linha 8). Em seguida, no laço das linhas 11 a 14 são selecionados aleatoriamente os  $t_P$  OAs que comporão aquele indivíduo. Por fim, nas linhas 15 e 16 o indivíduo formado é adicionado à população inicial  $PI$  que está sendo formada. Isso se repete até a obtenção dos  $m$  indivíduos da população inicial.

---

**Algorithm 3** Algoritmo de Geração da População Inicial por Seleção de OAs

---

**Require:**  $m$  (Tamanho da População),  $R$ (repositório dos OAs)

---

```

1:  $PI \leftarrow \emptyset$ ;
2:  $n \leftarrow$  Total de OAs do Repositório ( $N$ );
3:  $n' \leftarrow$  Inteiro Mais Próximo( $\frac{n}{10}$ );
4:  $i \leftarrow 0$ ;
5: repeat
6:    $i \leftarrow i + 1$ ;
7:    $P \leftarrow \emptyset$ ;
8:    $t_P \leftarrow$  Número de OAs da Solução( $n'$ );
9:    $j \leftarrow 0$ ;
10:   $v[] \leftarrow 0$ ;
11:  while  $j \leq t_P$  do
12:     $V[] \leftarrow$  Escolhe Novo OA ( $R$ );
13:     $j \leftarrow j + 1$ ;
14:  end while
15:   $P \leftarrow$  Adiciona Solução( $V[]$ );
16:   $PI \leftarrow PI \cup P$ ;
17: until  $i \leq m$ ;
18: return  $PI$ ;
```

---



## 6 RESULTADO

### 6.1 Resultados dos testes preliminares

Os testes iniciais foram realizados considerando dois conjuntos de parâmetros distintos, conforme elucidado na tabela 4. O primeiro é o método de geração da população inicial, onde foram utilizados o método randômico, padrão do MOEA, e o outro método por cobertura de conceitos, conforme demonstrado no algoritmo 1 na seção 5.1, que foi criado gerando indivíduos com valores aleatórios de quantidade de conceitos cobertos.

**Tabela 4 – Parâmetros dos testes executados**

| Teste | Método de Inicialização | População | Número de Gerações |
|-------|-------------------------|-----------|--------------------|
| 1     | Randômico               | 100       | 10000              |
| 2     | Por Cobertura           | 100       | 5000               |
| 3     | Randômico               | 200       | 10000              |
| 4     | Por Cobertura           | 200       | 5000               |

O segundo conjunto de parâmetros comparados foi o tamanho da população inicial gerada, que foi de 100 ou 200 indivíduos, bem como o número de gerações que o algoritmo executa, no qual foram testados 10000 ou 5000 gerações. Os parâmetros utilizados por padrão no MOEA são método de inicialização randômica, população de 100 indivíduos e 10000 gerações. Os demais parâmetros para execução do NSGA-II foram os mesmos para os quatro tipos de testes: a taxa de cruzamento igual a 1 e a taxa de mutação de  $\frac{1}{n}$ , sendo  $n$  o número de variáveis da população, com o método de seleção dos indivíduos por torneio. Foram testadas taxas de cruzamento menores que 1 e taxas de mutação maiores que  $\frac{1}{n}$ , porém não apresentaram melhores resultados na diversidade e qualidade das soluções.

Cada um dos testes foi executado 5 vezes para cada uma das instâncias. Na tabela 5 é apresentada a média e desvio-padrão dos resultados de cardinalidade das 5 execuções de cada teste para cada uma das instâncias. A sigla T1 se refere ao teste 1, T2 ao teste 2, e assim sucessivamente. Os resultados com maior cardinalidade estão destacados em negrito. Percebe-se que T2 e T4 obtiveram melhor desempenho, sendo esse último o de melhor desempenho na instância F2. Para essa métrica, percebe-se uma diferença significativa entre o método randômico de geração da população inicial (utilizado em T1 e T3) e o método demonstrado no algoritmo 1 (utilizado em T2 e T4). Em T1 e T3 houve uma única solução em média, nas 3 instâncias testadas.

Outra métrica utilizada na avaliação das soluções foi o hipervolume, muito útil para comparar o desempenho de dois conjuntos de soluções, pois calcula o volume do espaço dominado por um conjunto aproximado de soluções. Os resultados são apresentados na tabela 6, com os melhores resultados em negrito. Novamente, T2 e T4 são bem melhores que T1 e T3, sendo T4 o que apresenta melhores resultados para as instâncias maiores (F2 e F3).

**Tabela 5 – Média e desvio-padrão da cardinalidade das soluções**

| Instância | T1    |    | T2        |      | T3    |    | T4        |      |
|-----------|-------|----|-----------|------|-------|----|-----------|------|
|           | Média | DP | Média     | DP   | Média | DP | Média     | DP   |
| R3        | 1     | 0  | <b>6</b>  | 1,22 | 1     | 0  | <b>6</b>  | 1,1  |
| F2        | 1     | 0  | 14        | 1,34 | 1     | 0  | <b>19</b> | 2,55 |
| F3        | 1     | 0  | <b>12</b> | 1,79 | 1     | 0  | <b>12</b> | 3,56 |

**Tabela 6 – Média e desvio-padrão do hipervolume das soluções**

| Instância | T1    |                      | T2         |       | T3    |                      | T4           |       |
|-----------|-------|----------------------|------------|-------|-------|----------------------|--------------|-------|
|           | Média | DP                   | Média      | DP    | Média | DP                   | Média        | DP    |
| R3        | 0,019 | 0,002                | <b>0,6</b> | 0,087 | 0,021 | 0,002                | 0,559        | 0,181 |
| F2        | 0,011 | $5,5 \times 10^{-4}$ | 0,828      | 0,137 | 0,011 | $6,7 \times 10^{-4}$ | <b>0,91</b>  | 0,067 |
| F3        | 0,011 | $6,8 \times 10^{-4}$ | 0,758      | 0,128 | 0,011 | $6 \times 10^{-4}$   | <b>0,857</b> | 0,107 |


A terceira métrica é o  $\varepsilon$  aditivo, ou simplesmente  $\varepsilon_+$ . Ela calcula o menor valor necessário que o conjunto aproximado gerado precisa ser transladado para dominar um determinado conjunto de referência. Nesse caso, o conjunto de referência é formado pelas soluções não dominadas de todos os conjuntos gerados. Valores baixos desse indicador apontam para uma boa diversidade de soluções e boa proximidade entre a solução e o conjunto de referência. Os valores do  $\varepsilon$  aditivo estão indicados na tabela 7, na qual pode-se constatar novamente superioridade de T2 e T4 em relação a T1 e T3.

**Tabela 7 – Média e desvio-padrão do indicador  $\varepsilon_+$  das soluções**


| Instância | T1      |         | T2           |        | T3      |         | T4           |        |
|-----------|---------|---------|--------------|--------|---------|---------|--------------|--------|
|           | Média   | DP      | Média        | DP     | Média   | DP      | Média        | DP     |
| R3        | 69,038  | 4,773   | <b>3,208</b> | 1,782  | 64,915  | 4,252   | 4,415        | 3,348  |
| F2        | 248,533 | 3,71    | 5,163        | 4,084  | 244,899 | 4,562   | <b>2,336</b> | 1,999  |
| F3        | 11347,9 | 212,953 | 118,2        | 97,127 | 11420,4 | 190,262 | <b>33,6</b>  | 35,578 |

A figura 6 apresenta o gráfico de soluções de uma das 5 execuções do algoritmo para a instância R3. Nele se constata o motivo da diferença entre os grupos de testes T1/T3 e T2/T4: além do menor número de soluções, os valores de custo (pontos verde e vermelho) de T1 e T3 são muito maiores que os de T2 e T4, para uma mesma cobertura. Tal comportamento se repete nas instâncias maiores, conforme evidenciado nas figuras 7 e 8.

Analisando as mesmas figuras, com relação à distribuição das soluções ao longo da fronteira de Pareto, nota-se ainda que nas instâncias F2 e F3 há mais soluções com cobertura maior que 100 conceitos em relação ao número de soluções com cobertura menor que 100 conceitos, especialmente na instância F3. Na instância R3, que é de uma seção de aprendizagem de 20 conceitos, a distribuição das soluções também apresenta esse desequilíbrio.




**Figura 6 – Gráfico de soluções de uma execução dos testes na instância R3. Fonte: próprio autor.**



**Figura 7 – Gráfico de soluções de uma execução dos testes na instância F2. Fonte: próprio autor**

O resultado evidenciado parece ser diretamente influenciado pelo modo como é gerada a população inicial sobre a qual o NSGA II trabalha. O método de inicialização randômico gera valores aleatórios distribuídos entre os possíveis valores que a variável pode receber. Ocorre



**Figura 8 – Gráfico de soluções de uma execução dos testes na instância F3. Fonte: próprio autor**

que, no problema em questão, há uma variável associada a cada um dos Objetos de Aprendizagem, que pode assumir apenas dois valores (0 ou 1), os quais são gerados com igual probabilidade.

Isso faz com que, em cada solução gerada, esteja presente cerca de metade dos OAs de todo o repositório. Como cada OA cobre mais de um conceito, cada solução irá cobrir praticamente todos os conceitos da seção de aprendizagem. No entanto, por conter praticamente metade de todo o repositório, o custo de cada solução gerada é muito alto. Dessa maneira, do ponto de vista do problema aqui tratado, todos os indivíduos da população inicial gerado pelo método randômico possuem a mesma característica: a cobertura de quase todos os conceitos com um custo de solução elevado. O que o NSGA II acaba por fazer é reduzir um pouco do custo das soluções, selecionando a que possui melhor valor de custo e descartando as demais.

Já na inicialização com diferentes valores de cobertura, conforme indicado no algoritmo 1, o número de OAs presentes em cada solução é muito menor, e os indivíduos variam muito mais em termos de quantidade de conceitos cobertos e até mesmo do custo, pois quanto menos conceitos cobertos, a tendência é de haver menor número de OAs. Consequentemente, o custo da solução também é reduzido. Dessa maneira, o NSGA II consegue trabalhar com um conjunto de soluções mais diversificado e relacionado à realidade da otimização multiobjetivo, que é exatamente apresentar um conjunto de soluções ponderadas entre diferentes valores dos objetivos conflitantes.

## 6.2 Resultados dos testes como novos parâmetros

A partir dos resultados obtidos nos testes preliminares, foram executados novos testes com diferentes parâmetros. Observou-se que a grande discrepância entre resultados nos

**Tabela 8 – Parâmetros dos novos testes executados**

| Teste | Método de Inicialização | População | Número de Gerações |
|-------|-------------------------|-----------|--------------------|
| 1     | Seleção por Conceitos   | 150       | 2000               |
| 2     | Seleção por OAs         | 150       | 2000               |
| 3     | Seleção por Conceitos   | 300       | 1000               |
| 4     | Seleção por OAs         | 300       | 1000               |

testes preliminares ocorreu em relação à diferença de desempenho entre o algoritmo randômico do MOEA e aquele proposto no algoritmo 1.

Diante disso, o algoritmo randômico do MOEA não foi mais utilizado, dando lugar ao algoritmo 3, que também faz seleção aleatória de OAs, porém numa proporção menor em cada solução gerada. Uma nova versão do algoritmo 1 também foi utilizada, a qual se encontra apresentada no algoritmo 2, na seção 5.2. As características das novas instâncias de problemas utilizadas, assim como dos algoritmos de geração da população inicial utilizados nesses novos testes encontram-se detalhados na seção 5.2.

Foram realizados quatro novos testes conforme tabela 8, os quais foram executados cinco vezes, para cada uma das instâncias propostas para os novos testes (G2, G3 e F3), apresentadas no capítulo 5. Na tabela, o algoritmo 2 é denominado “Seleção por Conceitos” e o algoritmo 3, por sua vez, “Seleção por OAs”.

O número de gerações do algoritmo foi reduzido em relação aos testes preliminares, por não ter se verificado considerável influência desse parâmetro na qualidade das soluções para os testes já executados. Por sua vez, o tamanho da população inicial foi acrescido, pelo fato de soluções com populações iniciais maiores terem apresentado cardinalidade maior em algumas das execuções dos testes anteriores. Os demais parâmetros para execução do NSGA-II foram os mesmos dos testes preliminares, mantidos para os quatro tipos de testes: a taxa de cruzamento igual a 1 e a taxa de mutação de  $\frac{1}{n}$ , sendo  $n$  o número de variáveis da população, com o método de seleção dos indivíduos por torneio.

Cada um dos testes foi executado 5 vezes para cada uma das instâncias. Como nos testes preliminares, a sigla T1 se refere ao teste 1, T2 ao teste 2, e assim por diante. Os melhores resultados para cada métrica se encontram destacados em negrito.

Na tabela 9 se encontra a média e o desvio-padrão dos resultados de tempo de execução, em milissegundos, de cada um dos testes para as instâncias consideradas, com o menor tempo para cada instância destacado em negrito. Percebe-se que os testes T1 e T3, cujo método de inicialização foi de seleção por conceitos (algoritmo 2) dependeu um tempo maior que os testes com o método de seleção por OAs (algoritmo 3). Mesmo ao se analisar isoladamente T1 e T3, percebe-se a grande influência do método de inicialização da população sobre o tempo de execução total de cada teste. De fato, T3 teve tempo maior que T1, mesmo com a metade do

número de gerações executado para o NSGA-II. Isso porque em T3 o tamanho da população gerada é o dobro em relação a T1.

**Tabela 9 – Média e desvio-padrão do tempo de execução dos testes, em milissegundos**

| I  | T1      |           | T2     |          | T3      |           | T4            |                 |
|----|---------|-----------|--------|----------|---------|-----------|---------------|-----------------|
|    | Média   | DP        | Média  | DP       | Média   | DP        | Média         | DP              |
| F3 | 103.451 | 6.835,25  | 26.228 | 1.113,34 | 179.755 | 11.285,72 | <b>23.121</b> | <b>1.521,79</b> |
| G2 | 126.399 | 8.775,90  | 36.309 | 1.040,16 | 201.404 | 8.210,91  | <b>30.206</b> | <b>2.072,29</b> |
| G3 | 113.289 | 16.443,37 | 32.860 | 2.277,98 | 186.670 | 8.140,93  | <b>28.089</b> | <b>903,31</b>   |

Na tabela 10 se encontra a média e o desvio-padrão dos resultados de cardinalidade das 5 execuções para cada teste em cada instância. Os resultados com maior cardinalidade estão destacados em negrito. Percebe-se que os testes com maior população inicial (T3 e T4) obtiveram melhor desempenho, sendo que T4 se saiu melhor nas instâncias G3 e F3, cuja matriz de cobertura é mais densa.

**Tabela 10 – Média e desvio-padrão da cardinalidade das soluções**

| Instância | T1    |      | T2    |      | T3        |             | T4        |             |
|-----------|-------|------|-------|------|-----------|-------------|-----------|-------------|
|           | Média | DP   | Média | DP   | Média     | DP          | Média     | DP          |
| F3        | 10    | 0,84 | 16    | 4,44 | 16        | 1,58        | <b>19</b> | <b>1,92</b> |
| G2        | 9     | 2    | 6     | 2,97 | <b>14</b> | <b>1,52</b> | 9         | 1,22        |
| G3        | 6     | 2,07 | 8     | 2,07 | 9         | 1,3         | <b>10</b> | <b>2,59</b> |

A figura 9 apresenta uma das execuções para a instância F3, na qual é possível verificar o menor número de soluções que T1 (pontos em vermelho) em relação aos outros testes. T1 tem o método geração da população diferente de T2 e T4 e a metade da população inicial de T3.

O hipervolume também foi uma métrica utilizada para avaliação das soluções, conforme tabela 11. Nessa métrica, o teste 4 apresentou os melhores indicadores para todas as instâncias. Isso demonstra que a maior cardinalidade que T3 obteve na instância G2 não se traduziu em qualidade das soluções. A figura 10 mostra uma das execuções para G2. Nela é possível notar que, apesar de mais numerosas, as soluções de T3 (em verde) encontram-se concentradas majoritariamente em uma única área do conjunto aproximado, com altos valores de cobertura e custo. Por outro lado, T4 (em amarelo), embora seja menos numeroso, está mais distribuído ao longo da fronteira, sobretudo em valores intermediários de cobertura, como 30 e 130.

Ainda com relação ao hipervolume, nota-se o alto desvio-padrão dos testes T1 e T2 principalmente na instância G3, que possui matriz de cobertura menos esparsa e um número alto de dependências entre conceitos. Essa discrepância se dá pelo fato de algumas execuções desses






Figura 9 – Gráfico de soluções de uma execução dos testes na instância F3. Fonte: próprio autor.

Tabela 11 – Média e desvio-padrão do hipervolume das soluções


| Instância | T1    |      | T2    |      | T3    |      | T4          |             |
|-----------|-------|------|-------|------|-------|------|-------------|-------------|
|           | Média | DP   | Média | DP   | Média | DP   | Média       | DP          |
| F3        | 0,79  | 0,29 | 0,93  | 0,05 | 0,82  | 0,07 | <b>0,95</b> | <b>0,02</b> |
| G2        | 0,80  | 0,37 | 0,80  | 0,36 | 0,82  | 0,33 | <b>0,98</b> | <b>0</b>    |
| G3        | 0,57  | 0,45 | 0,47  | 0,43 | 0,84  | 0,19 | <b>0,95</b> | <b>0,03</b> |

testes terem obtido um pequeno número de soluções e por conseguinte um espaço dominado menor.

O teste T4 também performou melhor em relação ao indicador  $\varepsilon$  aditivo nas três instâncias consideradas, conforme tabela 12. Os valores de T4 são consideravelmente menores que os demais testes principalmente para as instâncias G2 e G3, que possuem um maior número de dependências entre os conceitos. Baixos valores do indicador  $\varepsilon$  aditivo indicam que a solução de T4 está mais próxima do conjunto de melhores soluções encontradas, a qual engloba todas as soluções não-dominadas obtidas em todos os testes.

Tabela 12 – Média e desvio-padrão do indicador  $\varepsilon_+$  das soluções

| Instância | T1    |        | T2     |        | T3    |        | T4          |             |
|-----------|-------|--------|--------|--------|-------|--------|-------------|-------------|
|           | Média | DP     | Média  | DP     | Média | DP     | Média       | DP          |
| F3        | 19,27 | 29,54  | 5,51   | 4,14   | 15,40 | 7,37   | <b>2,90</b> | <b>2,46</b> |
| G2        | 97,71 | 196,45 | 121,07 | 244,22 | 63,02 | 136,09 | <b>1,79</b> | <b>1,25</b> |
| G3        | 28,27 | 31,33  | 35,20  | 29,42  | 9,29  | 13,26  | <b>2,00</b> | <b>1,80</b> |




**Figura 10 – Gráfico de soluções de uma execução dos testes na instância G2. Fonte: próprio autor.**

Na figura 11 se encontra a representação dos pontos de uma das execuções dos testes para a instância G3. Nele é possível perceber que as soluções de T4 (em amarelo), embora ligeiramente dominadas por soluções de outros testes, estão um pouco mais distribuídas ao longo do espaço de possíveis soluções. Isso faz com que o deslocamento dessas soluções para dominar o conjunto de referência seja menor, o que se reflete em seus valores do indicador  $\varepsilon_+$ .

Ademais, ao se analisar a tabela 10 com o resultado de cardinalidade das soluções, bem como ao se comparar o gráfico de soluções de F3 com os gráficos de soluções de G2 e G3, é possível notar que houve diminuição do número de soluções obtidos pelo NSGA-II nas instâncias com maior número de dependências. É possível notar que tal decréscimo se acentua principalmente nas soluções com cobertura média, isto é, aquelas que cobrem mais de 40 conceitos e menos de 160 conceitos.

A existência de muitas dependências entre conceitos pode ter feito com que a maioria dos indivíduos da população inicial com coberturas médias não respeitassem pelo menos alguma das restrições do *design* instrucional. Com isso, formaram-se várias soluções inicialmente inviáveis que não tiveram sua inviabilidade revertida ao longo da execução do NSGA-II, acabando por serem descartadas. Tais restrições não afetaram de modo tão contundente as soluções com altos valores de cobertura, as quais atendem todas as dependências exigidas. Também não prejudicaram a geração de soluções com baixa cobertura, pelo fato dessas possivelmente estarem formadas apenas por conceitos que não dependam de outros. Os resultados obtidos a partir dos experimentos realizados indicam pela possibilidade de utilização do NSGA-II para gerar diferentes configurações conceituais de uma seção de aprendizagem para um estudante, numa



**Figura 11 – Gráfico de soluções de uma execução dos testes na instância G3. Fonte: próprio autor.**

proposta de *design* instrucional contextualizado, na qual existem relações de dependências entre conceitos que devam ser respeitadas.

No entanto, para haver uma diversidade maior de soluções, sobretudo aquelas com cobertura média, faz-se necessário métodos de inicialização da população que demandem maior custo computacional, de modo a garantir que todas as soluções inicialmente geradas sejam viáveis. Isso se torna mais imprescindível em problemas com um número maior de dependências entre conceitos.



## 7 CONCLUSÃO

O aumento do ensino a distância, assim como da utilização das ferramentas de tecnologia de informação e comunicação (TICs) tem impulsionado a criação e utilização de recursos educacionais digitais diversos. Todavia, esse avanço vem acompanhado de desafios, dentre os quais pode-se destacar a seleção adequada dos conteúdos educacionais, dentro da infinidade de itens de repositórios diferentes, de acordo com as necessidades e preferências tanto de professores como alunos.

O presente trabalho apresentou um problema com abordagem multiobjetivo de recomendação de objetos de aprendizagem, para uma seção de aprendizagem cujo *design* instrucional contextualizado permite que nem todos os conceitos precisem ser cobertos, ressalvadas as relações de dependência existentes entre alguns deles.

Os objetivos de otimização considerados foram o custo da solução e a sua cobertura. O custo da solução é determinado pela soma do custo de cada objeto de aprendizagem que o compõe. Por sua vez, o custo de cada OA é variável, dependendo da sua adequabilidade em relação ao estilo de aprendizagem do aluno, considerando ainda a avaliação daquele OA por outros estudantes com estilo de aprendizagem semelhante. A cobertura é calculada pela quantidade de conceitos do curso ou seção de aprendizagem almejada que a solução composta pelos OAs selecionados cobre, haja vista que a obrigatoriedade de se cobrir todos os conceitos foi relaxada, embora haja a necessidade da presença de um determinado conceito em uma solução caso haja outro conceito que dependa dele.

A resolução do problema foi executada em instâncias geradas artificialmente, sendo utilizado o algoritmo NSGA-II para tal, implementado no *framework* MOEA. Distintos números de gerações e tamanhos de população inicial foram empregados. Foram utilizados ainda dois algoritmos de geração da população inicial para o NSGA-II. Um deles criava soluções a partir de valores aleatórios mínimos de cobertura que eram estabelecidos. O outro método selecionava aleatoriamente um OA do repositório para fazer parte de uma solução, cujo número de OAs também era definido de modo randômico.

Os resultados obtidos demonstram pela aplicabilidade do NSGA-II no problema proposto, com boa diversidade de soluções em instâncias com poucas dependências estabelecidas entre conceitos. No entanto, para os cursos em que a quantidade de dependências é maior verificou-se uma diminuição na diversidade de soluções, sobretudo aquelas com valores médios de cobertura. Mostra-se necessário, portanto, o emprego de novas estratégias para gerar um conjunto de soluções mais diverso.

Os objetivos propostos foram alcançados, haja vista que a modelagem para o problema contemplou de forma satisfatória a proposta de abordagem multiobjetivo para a recomendação de OAs. Ademais, a técnica heurística implementada se mostrou capaz de gerar soluções em problemas com diferentes características.



## 8 TRABALHOS FUTUROS

Entre as possibilidades de trabalhos futuros, pode-se destacar a aplicação do problema proposto em um contexto real, que pode se dar a partir da construção de um repositório de objetos de aprendizagem a partir de conteúdos educacionais que estejam disponíveis em outros repositórios como a Wikipédia e o Youtube.

É necessário também testar o desempenho de outros algoritmos além do NSGA-II, sejam eles evolucionários ou não. Outra ação importante é verificar a possibilidade de utilização de métodos exatos para resolução das instâncias testadas para o problema, de modo a verificar quão próximas da fronteira de Pareto Ótima estão as soluções geradas pelo algoritmo. Além disso, faz-se necessário a criação de métodos de geração da população inicial mais robustos e custosos computacionalmente, de modo a assegurar que as soluções iniciais geradas sejam viáveis. Isso permitiria maior diversidade de soluções quando o número de restrições do problema - nesse caso, dependências entre conceitos - for grande.

Com relação ao problema proposto, uma outra possibilidade a ser explorada é garantir que os conceitos da seção de aprendizagem sejam ordenados, de modo a se ter uma sequência de aprendizagem, na qual o conjunto de OAs escolhidos respeitem essa ordenação. Essa é uma possibilidade que, embora traga maior complexidade para lidar com o problema, mostra-se pedagogicamente mais assertiva. Deve-se ainda investigar diferentes aspectos relacionados ao *design* instrucional dos cursos, que não apenas os conceitos e suas relações de dependência, que possam ser trabalhados e explorados numa perspectiva de otimização multiobjetivo.





## REFERÊNCIAS

- ABED, A. B. d. E. a. D. **Censo EAD.BR: relatório analítico da aprendizagem a distância no Brasil**. Sao Paulo, 2019. 212 p.
- AHMADI, M. H.; HOSSEINZADE, H.; SAYYAADI, H.; MOHAMMADI, A. H.; KIMIAGHALAM, F. Application of the multi-objective optimization method for designing a powered Stirling heat engine: Design with maximized power, thermal efficiency and minimized pressure loss. **Renewable Energy**, v. 60, p. 313–322, 2013. ISSN 09601481.
- APPS, B. of. **YouTube Revenue and Usage Statistics (2020) - Business of Apps**. 2020. Disponível em: <https://www.businessofapps.com/data/youtube-statistics/>.
- ASSIS, L. P. D. E. **Investigação de metaheurísticas aplicadas ao problema de roteamento de veículos multiobjetivo com coleta opcional**. Tese (Doutorado), 2013.
- BEASLEY, J. E.; CHU, P. C. A genetic algorithm for the set covering problem. **European Journal of Operational Research**, Elsevier, v. 94, n. 2, p. 392–404, oct 1996. ISSN 03772217.
- BOURKOUKOU, O.; El Bachari, E. Toward a Hybrid Recommender System for E-learning Personalization Based on Data Mining Techniques. **JOIV : International Journal on Informatics Visualization**, Politeknik Negeri Padang, v. 2, n. 4, p. 271, aug 2018. ISSN 2549-9610.
- CERQUEIRA, T. C. S. **Estilos de aprendizagem em universitários**. Tese (Doutorado) — Universidade Estadual de Campinas, Campinas, feb 2000. Disponível em: <http://repositorio.unicamp.br/jspui/handle/REPOSIP/253390>.
- CLARK, R. C.; MAYER, R. E. **E-learning and the science of instruction: Proven guidelines for consumers and designers of multimedia learning**. [S.l.]: John Wiley & Sons, 2016.
- CURY, H. N. ESTILOS DE APRENDIZAGEM DE ALUNOS DE ENGENHARIA. In: **XXVIII CONGRESSO BRASILEIRO DE ENSINO DE ENGENHARIA**. Ouro Preto: [s.n.], 2000.
- DCM, I.; OTHERS. Dcmi metadata terms. **World Wide Web electronic publication**, 2008. Disponível em: <http://www.dublincore.org/documents/dcmi-terms/>.
- DEB, K.; AGRAWAL, S.; PRATAP, A.; MEYARIVAN, T. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, Springer, Berlin, Heidelberg, v. 1917, p. 849–858, 2000. ISSN 16113349. Disponível em: [https://link.springer.com/chapter/10.1007/3-540-45356-3\\_83](https://link.springer.com/chapter/10.1007/3-540-45356-3_83).
- EHRGOTT, M. **Multicriteria Optimization**. [s.n.], 2006. ISBN 3540276599. Disponível em: <https://books.google.com/books?hl=pt-BR{&}lr={&}id=AwRjo6iP4{\-}>.
- FELDER, R. M.; SILVERMAN, L. K. *et al.* Learning and teaching styles in engineering education. **Engineering education**, v. 78, n. 7, p. 674–681, 1988.
- FELDER, R. M.; SPURLIN, J. Applications, reliability and validity of the index of learning styles. **International journal of engineering education**, Ontario, v. 21, n. 1, p. 103–112, 2005.
- FILATRO, A.; CAIRO, S. **Produção de Conteúdos Educacionais**. Sao Paulo: Saraiva, 2015. 480 p. ISBN 9788502635883.

FILATRO, A.; PICONEZ, S. C. B. Design instrucional contextualizado. **São Paulo: Senac**, p. 27–29, 2004.

FILATRO, A. C. **Learning design como fundamentação teórico-prática para o design instrucional contextualizado**. Tese (Doutorado) — Universidade de São Paulo, São Paulo, apr 2008. Disponível em: <http://www.teses.usp.br/teses/disponiveis/48/48134/tde-12062008-142556/>.

GILL, L.; DALGARNO, B. A qualitative analysis of pre-service primary school teachers' TPACK development over the four years of their teacher preparation programme. **Technology, Pedagogy and Education**, Routledge, v. 26, n. 4, p. 439–456, aug 2017. ISSN 17475139. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/1475939X.2017.1287124>.

GOLDBARG, M. C.; LUNA, H. P. L. **Otimização combinatória e programação linear: modelos e algoritmos**. [s.n.], 2005. 518 p. ISBN 8535215204. Disponível em: <http://books.google.com/books?id=Q-bNGAAACAAJ{&}pgi>.

GRASHA, A. F. **Teaching with style: A practical guide to enhancing learning by understanding teaching and learning styles**. [S.l.]: Alliance publishers, 1996.

GUTJAHR, W. J.; PICHLER, A. Stochastic multi-objective optimization: a survey on non-scalarizing methods. **Annals of Operations Research**, Springer US, v. 236, n. 2, p. 475–499, jan 2016. ISSN 0254-5330. Disponível em: <http://link.springer.com/10.1007/s10479-013-1369-5>.

HASSAN, M.; HAMADA, M. Enhancing learning objects recommendation using multi-criteria recommender systems. In: **2016 IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALE)**. IEEE, 2016. p. 62–64. ISBN 978-1-5090-5598-2. Disponível em: <http://ieeexplore.ieee.org/document/7851771/>.

IEEE. **Learning Technology Standards Committee (LTSC)**. 2002. Disponível em: <http://ltsc.ieee.org/wg12/files/LOM1484121v1FinalDraft.pdf>.

IMS. **Ims global learning consortium**. 2019. Disponível em: <https://www.msglobal.org/>.

INEP, i. N. d. E. e. P. E. A. T. **Censo da Educação Superior**. Brasília, 2019. 44 p.

JACOBSON, L. V. **A contribuição do e-learning no desenvolvimento de competências do administrador: considerando o estilo de aprendizagem do aluno de graduação**. Tese (Doutorado) — Universidade de São Paulo, São Paulo, oct 2003. Disponível em: <http://www.teses.usp.br/teses/disponiveis/12/12139/tde-06012004-133938/>.

JÚNIOR, C. B.; DORÇA, F. Uma Abordagem para a Criação e Recomendação de Objetos de Aprendizagem usando um Algoritmo Genético, Tecnologias da Web Semântica e uma Ontologia. In: **Anais do XXIX Simpósio Brasileiro de Informática na Educação (SBIE 2018)**. Brazilian Computer Society (Sociedade Brasileira de Computação - SBC), 2018. v. 1, n. 1, p. 1533. Disponível em: <https://br-ie.org/pub/index.php/sbie/article/view/8114>.

KONAK, A.; COIT, D. W.; SMITH, A. E. Multi-objective optimization using genetic algorithms: A tutorial. **Reliability Engineering & System Safety**, v. 91, n. 9, p. 992–1007, 2006. ISSN 09518320.

LUENBERGER, D. G.; YINYU, Y. **Linear and Nonlinear Programming**. [s.n.], 2016. Disponível em: <http://rd.springer.com/book/10.1007/978-3-319-18842-3>.

MARAVILHA, A. L. S. Abordagem multiobjetivo para um problema de roteamento de veículos com serviços de entrega e coleta opcional. 2011.

MEDIO, C. D.; GASPARETTI, F.; LIMONGELLI, C.; SCIARRONE, F. Automatic extraction and sequencing of wikipedia pages for smart course building. In: IEEE. **2017 21st International Conference Information Visualisation (IV)**. [S.l.], 2017. p. 378–383.

MOEA, F. **MOEA Framework, a Java library for multiobjective evolutionary algorithms**. 2020. Disponível em: <http://moeaframework.org/>.

MOREIRA, M. M.; ARAÚJO, ; TORRES, A. C. U.; ; JOYE, A. L. d. M. M.; ; NETO, C. R.; BORGES, H. ENSAIO TEÓRICO SOBRE O DESIGN INSTRUCIONAL CONTEXTUALIZADO E AS ESTRATÉGIAS DIDÁTICAS NA ELABORAÇÃO DE MATERIAL DIDÁTICO PARA EAD ONLINE. **EmRede - Revista de Educação a Distância**, v. 6, n. 1, p. 43–52, 2019. Disponível em: <https://www.aunirede.org.br/revista/index.php/emrede/article/view/389>.

MURAD, H.; YANG, L. Personalized e-learning recommender system using multimedia data. **International Journal of Advanced Computer Science and Applications**, Science and Information Organization, v. 9, n. 9, p. 565–567, oct 2018. ISSN 21565570. Disponível em: [www.ijacsa.thesai.org](http://www.ijacsa.thesai.org).

PIREVA, K.; KEFALAS, P. A recommender system based on hierarchical clustering for cloud e-learning. **Studies in Computational Intelligence**, Springer Verlag, v. 737, p. 235–245, oct 2017. ISSN 1860949X. Disponível em: [https://link.springer.com/chapter/10.1007/978-3-319-66379-1\\_21](https://link.springer.com/chapter/10.1007/978-3-319-66379-1_21).

REIGELUTH, C. M. The elaboration theory: Guidance for scope and sequence decisions. **Instructional-design theories and models**, v. 2, p. 425–453, 1999.

RODRIGUES, P. A. A.; RODRIGUES, L. M.; DIAS, L. C. M. DO DESIGN INSTRUCIONAL FIXO AO CONTEXTUALIZADO: ANÁLISE DE UM CURSO DE PÓS-GRADUAÇÃO OFERECIDO NA MODALIDADE A DISTÂNCIA. In: **SIED:EnPED - Simpósio Internacional de Educação a Distância e Encontro de Pesquisadores em Educação a Distância**. [s.n.], 2014. v. 0, n. 0. ISSN 2316-8722. Disponível em: <http://www.sied-enped2014.ead.ufscar.br/ojs/index.php/2014/article/view/761>.

SANTOS, M.; ANDRADE, F.; SILVA, J. M. C. da; IMRAN, H. Learning Object Recommendation System Evaluation. In: **2016 IEEE 16th International Conference on Advanced Learning Technologies (ICALT)**. IEEE, 2016. p. 412–413. ISBN 978-1-4673-9041-5. Disponível em: <http://ieeexplore.ieee.org/document/7757010/>.

SCHMITT, C. d. S.; DOMINGUES, M. J. C. d. S. Estilos de aprendizagem: um estudo comparativo. **Avaliação: Revista da Avaliação da Educação Superior (Campinas)**, FapUNIFESP (SciELO), v. 21, n. 2, p. 361–386, jul 2016. ISSN 1414-4077. Disponível em: <http://dx.doi.org/10.1590/S1414-40772016000200004>.

SERGIS, S.; SAMPSON, D. G. Learning Object Recommendations for Teachers Based On Elicited ICT Competence Profiles. **IEEE Transactions on Learning Technologies**, v. 9, n. 1, p. 67–80, jan 2016. ISSN 1939-1382. Disponível em: <http://ieeexplore.ieee.org/document/7109912/>.

SILVA, D. M. da. **O impacto dos estilos de aprendizagem no ensino de contabilidade na FEA-RP/USP**. Tese (Doutorado) — Universidade de São Paulo, Ribeirão Preto, dec 2006. Disponível em: <http://www.teses.usp.br/teses/disponiveis/96/96133/tde-24012007-152550/>.

SINDHYA, K.; MIETTINEN, K.; DEB, K. A Hybrid Framework for Evolutionary Multi-Objective Optimization. **IEEE Transactions on Evolutionary Computation**, v. 17, n. 4, p. 495–511, aug 2013. ISSN 1089-778X. Disponível em: <http://ieeexplore.ieee.org/document/6216406/>.

SOLOMAN, B. A.; FELDER, R. M. Index of learning styles questionnaire. **NC State University**. Available online at: <http://www.engr.ncsu.edu/learningstyles/ilsweb.html> (last visited on 14.05. 2010), v. 70, 2005.

VENKATESH, M.; SATHYALAKSHMI, S. Smart learning using personalised recommendations in web-based learning systems using artificial bee colony algorithm to improve learning performance. **Electronic Government**, Inderscience Publishers, v. 16, n. 1-2, p. 101–117, 2020. ISSN 17407508.

VIRA, C.; HAIMES, Y. Y. Multiobjective decision making: theory and methodology. **North Holland series in system science and engineering**, North-Holland, n. 8, 1983. Disponível em: <http://bases.bireme.br/cgi-bin/wxislind.exe/iah/online/?IsisScript=iah/iah.xis{&}src=google{&}base=REPIDISCA{&}lang=p{&}nextAction=lnk{&}exprSearch=132053>.

WIKIPEDIA. **Wikipedia, the free encyclopedia**. 2020. Disponível em: [https://en.wikipedia.org/wiki/Main\\_Page](https://en.wikipedia.org/wiki/Main_Page).

WILEY, D. A. **The Instructional Use of Learning Objects**. 1.<sup>a</sup> ed. Bloomington,: Agency for InstructionalTechnology, 2002. ISBN 0784208921. Disponível em: [www.ait.net](http://www.ait.net).

ZITZLER, E. **Evolutionary algorithms for multiobjective optimization: Methods and applications**. [S.l.]: Citeseer, 1999. v. 63.

## **ANEXO A – PUBLICAÇÃO**

## Sistemas de Recomendação em Ambientes Educacionais: Estado da Arte e Perspectivas Futuras

Ramon R. Leite<sup>1</sup>, Cristiano G. Pitangui<sup>2</sup>, Luciana P. de Assis<sup>1</sup>, Alessandro V. Andrade<sup>1</sup>

<sup>1</sup>Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM)

<sup>2</sup>Universidade Federal de São João Del Rei (UFSJ)

{ramon.leite, lpassis}@ufvjm.edu.br

{pitangui.cristiano, alessandro.vivas}@gmail.com

**Abstract.** *The use of Recommendation Systems in the Educational area has been growing in recent years. Such interest is justified since the large amount of content produced from e-learning needs to be filtered and selected to meet users' needs and preferences. The present work reviews the current literature to analyse how the Recommendation Systems are being used in the Educational context. We conducted a research in works from 2016 to 2019, where it was noticed that there are few systems that rely on specific concepts of psychology or pedagogy. It has also been noted that many datasets used to test the systems are not in the public domain. Finally, it was verified that there are techniques that can be better explored, such as the multiobjective recommendation, for example.*

**Resumo.** *O uso dos Sistemas de Recomendação no ambiente Educacional vem crescendo nos últimos anos. Tal interesse se justifica já que a grande quantidade de conteúdo produzido a partir do e-learning precisa ser filtrada para atender as preferências dos usuários. Este trabalho realiza um estudo dos trabalhos mais recentes da área, no período de 2016 a 2019, com objetivo de apontar o estado da arte atual da pesquisa no tema. Percebeu-se que há poucos sistemas que se apoiam em conceitos específicos da psicologia ou pedagogia. Notou-se, ademais, que muitas bases de dados utilizadas para testar os sistemas não são públicas. Por fim, verificou-se que existem técnicas que podem ser melhor exploradas, como a recomendação multiobjetivo, por exemplo.*

### 1. Introdução

A grande quantidade de conteúdo disponível na *Web* faz com que sejam criadas estratégias para filtrar a informação de acordo com as necessidades dos usuários. Um desses mecanismos são os Sistemas de Recomendação, responsáveis por fornecerem aos usuários os itens que de fato correspondam às suas preferências e objetivos [Hassan and Hamada 2016].

[Bobadilla et al. 2013] definem Sistemas de Recomendação como programas que buscam recomendar itens - produtos ou serviços - a usuários, a partir da previsão do interesse dos mesmos. Esse interesse é definido a partir de, por exemplo, informações dos próprios usuários, dos itens disponíveis e das interações entre os usuários e esses itens.

[Ricci et al. 2015] afirmam que os Sistemas de Recomendação são ferramentas e técnicas empregadas para sugerir itens aos usuários que os utilizam. Portanto, eles se tornam um meio valioso para se decidir desde o que comprar até o que se ler. Por esse motivo, são amplamente empregados em áreas como comércio eletrônico e serviços de *streaming*. Um outro campo cuja utilização dos Sistemas de Recomendação vem ganhando destaque é no *e-learning*. Tendo em vista o crescimento da quantidade de conteúdo disponível nos inúmeros cursos que são criados, ferramentas que selecionem os tipos de itens de acordo com os objetivos e preferências do estudante tornaram-se indispensáveis.

Grande parte do conteúdo disponível no ambiente educacional está organizado sob a forma de Objetos de Aprendizagem (OA). O IEEE (*Institute of Electrical and Electronics Engineers*) define Objeto de Aprendizagem como “qualquer entidade, digital ou não, que pode ser utilizada para aprendizagem, educação ou capacitação” [IEEE 2002]. Os OAs são compostos basicamente pelo seu conteúdo propriamente dito (texto, áudio, imagem, vídeo, etc.) e pelos metadados que os descrevem (nome, autor, nível de dificuldade, ano de criação, tipo de conteúdo, etc.). Geralmente, esses itens estão organizados em repositórios, os chamados LORs (*Learning Object Repositories*).

De modo a facilitar a reutilização e interoperabilidade de tais repositórios, os OAs costumam seguir determinados padrões dos seus metadados, de forma a descrever o que eles contêm. Alguns desses padrões são IEEE LOM (*IEEE standard for learning object metadata*) [IEEE 2002], IMS-CP [IMS 2019] e Dublin-CORE [D C M and Others 2008].

Várias pesquisas na área de Sistemas de Recomendação no âmbito Educacional têm sido desenvolvidas. Entre elas, encontram-se os Sistemas de Recomendação de Objetos de Aprendizagem. Muitas abordagens são encaminhadas com o objetivo de recomendar os OAs que melhor correspondam aos anseios do estudante [Santos et al. 2016]. Entre as técnicas, a filtragem colaborativa e a recomendação baseada em conteúdo são muito utilizadas. A primeira consiste em prover a recomendação de itens a um usuário a partir de avaliações que usuários com perfil semelhante fizeram acerca daquele item. Por outro lado, a segunda técnica se baseia nas propriedades semelhantes que um item já utilizado pelo usuário tenha com um outro OA que possa ser recomendado [Sergis and Sampson 2016].

Ambas as abordagens possuem limitações. Quando se possui pouca ou nenhuma informação sobre o usuário, torna-se muito difícil a realização de recomendações. Tal problema é conhecido por *cold start*. Desse modo, há inúmeras outras estratégias utilizadas para tentar lidar com essa e outras limitações que surgem em cada situação.

Dentre as abordagens encontradas na literatura, podem-se listar os Sistemas de Recomendação baseados em Ontologia, que utilizam um domínio específico de conhecimento no qual o usuário se encontra, para facilitar a identificação das preferências. Há a recomendação por contexto, considerando, por exemplo, o horário e o dia em que se está utilizando o sistema. Há ainda abordagens que aplicam Lógica Fuzzy [Sergis and Sampson 2016], Redes Neurais [Yao 1999], Algoritmo Genético [Katarya and Verma 2018] e Computação Bioinspirada [Hassan and Hamada 2016].

Expostos o contexto e algumas abordagens relacionadas ao tema, o presente trabalho busca compreender, por meio de uma revisão atual da literatura, o estado da arte no tocante ao emprego dos Sistemas de Recomendação no âmbito Educacional. Com isso,

procura identificar, a partir de alguns aspectos, como esse tema tem sido estudado pela comunidade acadêmica, além de indicar possíveis lacunas ainda pouco ou não exploradas.

Este trabalho se organiza como segue. A seção 2 apresenta a metodologia adotada para a realização desta pesquisa. A seção 3 apresenta os trabalhos resultantes da revisão, com um breve resumo de cada um deles. A seção 4 analisa e discute os trabalhos selecionados de acordo com alguns critérios definidos. Por fim, a seção 5 aponta alguns desafios presentes na área de estudo, bem como algumas possibilidades de pesquisa em aberto.

## 2. Metodologia de Pesquisa

Para o levantamento do estado da arte sobre o tema abordado, pesquisou-se por artigos que trabalhavam a temática de Sistemas de Recomendação no ambiente Educacional. As bases de busca primárias foram o *IEEE Explore* e *Springer*, além do *Google Scholar*, que foi utilizado subsidiariamente na identificação de outros trabalhos disponíveis não contemplados nessas bases e que pudessem ser relevantes para o objetivo desse trabalho.

Para cumprimento do objetivo de pesquisa supramencionado, os termos de busca utilizados foram “*recommender system*” e “*educational*”, “*recommender system*” e “*education*”, “*recommender system*” e “*learning objects*” e “*learning objects recommender system*”. O período de busca foi estabelecido entre o ano de 2016 e o primeiro semestre de 2019. Com essa restrição de período, buscou-se concentrar no estágio bem atual da pesquisa nesse campo.

Estabelecidos os critérios e objetivos, passou-se ao processo de busca propriamente dito. A seleção dos artigos deu-se pela relação dos trabalhos com a temática pretendida pela presente revisão. Analisaram-se, num primeiro estágio, o título dos artigos, descartando aqueles se podia depreender não haver relação com o objeto da pesquisa. O critério de exclusão foi os trabalhos que não abordavam conjuntamente sistemas de recomendação e ambiente educacional. Essa etapa resultou em 21 artigos selecionados.

A seguir, passou-se à análise dos resumos e palavras-chave. Nessa fase, foram retirados 3 artigos cujo enfoque era revisão da literatura. A leitura do corpo do artigo foi a última etapa para eliminação dos trabalhos, realizada principalmente a partir dos objetivos, metodologia e ferramenta proposta, para selecionar aqueles que melhor contribuíssem para o objetivo do presente trabalho. Esta etapa culminou na remoção de mais 5 artigos, que ofereciam poucas possibilidades de se identificar o mecanismo de recomendação ou o modo como ele foi aplicado.

Os 13 artigos resultantes foram analisados e agrupados segundo alguns critérios pré-definidos, a saber: abordagem e técnica de recomendação, estágio de aplicação do sistema (somente modelado, apenas implementado ou já aplicado) e disponibilidade da base de dados utilizada no experimento. Também foi analisado quais artigos utilizaram fundamentações teóricas da psicologia ou pedagogia. Por fim, a partir desses e de outros critérios, foram externados alguns desafios a serem enfrentados nessa área, bem como possibilidades em aberto a serem exploradas.

## 3. Trabalhos Estudados

Os Sistemas de Recomendação para fins Educacionais têm despertado interesse da comunidade científica. Todavia, ainda há caminhos a serem explorados. No processo de



revisão da literatura concentrada no período de 2016 a 2019, foram selecionados os artigos constantes na tabela 1, os quais se encontram detalhados a seguir.

**Tabela 1. Lista de trabalhos considerados na análise da literatura**

| ID   | Trabalhos                       |
|------|---------------------------------|
| [1]  | [Zhang et al. 2017]             |
| [2]  | [Imran et al. 2016]             |
| [3]  | [Hassan and Hamada 2016]        |
| [4]  | [Santos et al. 2016]            |
| [5]  | [Hassan and Hamada 2017]        |
| [6]  | [Gulzar et al. 2018]            |
| [7]  | [Dascalu et al. 2016]           |
| [8]  | [Sergis and Sampson 2016]       |
| [9]  | [Hoic-Bozic et al. 2016]        |
| [10] | [Limongelli et al. 2016]        |
| [11] | [Sweeney et al. 2016]           |
| [12] | [Klašnja-Milićević et al. 2018] |
| [13] | [da S. Dias and Wives 2019]     |

[Imran et al. 2016] propõem um Sistema de Recomendação de Objetos de Aprendizagem personalizado, que está integrado dentro de um Sistema de Gerenciamento de Aprendizagem (LMS) - *Learning Management System*. O sistema busca recomendar OAs a partir dos OAs que o próprio usuário visitou ou que outros estudantes com perfis semelhantes visitaram. Para se obter as informações de histórico de utilização e comportamento do usuário, são verificados os *logs* de acesso e utilização do sistema que contém a plataforma do curso. O sistema foi utilizado dentro de um curso, mas a eficácia das recomendações não foi mencionada.

[Hassan and Hamada 2016] exploram o fato de que os Sistemas de Recomendação Educacionais geralmente utilizam um único valor de avaliação do usuário para prever o seu grau de interesse no OA. Todavia, as preferências do usuário podem depender de mais de um tipo de atributo daquele OA, por exemplo, autor, preço e nível de dificuldade. Nesse contexto, os autores criam um Sistema de Recomendação multi-critério, que modela e estima as preferências do usuário usando não mais um único atributo de avaliação, mas sim um vetor, que contempla o valor de avaliação para cada atributo do OA. A técnica utiliza uma Rede Neural Artificial para a tarefa de aprender a recomendar. Os autores mencionam como próxima etapa do trabalho a integração do recomendador a um LMS.

[Santos et al. 2016] investigam como um Sistema de Recomendação auxilia os usuários a encontrarem OAs adequados. O repositório analisado é de uma instituição educacional brasileira, que usa o padrão de metadados OBAA. É proposto um algoritmo de recomendação baseado em conteúdo. Para tratar o problema e realizar cálculos de similaridade do conteúdos, são utilizados o Modelo de Espaço Vetor e o Raciocínio Baseado em Casos [Aamodt and Plaza 1994]. Os participantes da pesquisa relataram, em sua maioria, que as recomendações foram relativamente úteis ou significativamente úteis. Concluiu-se também que os usuários obtêm informações de modo mais rápido se souberem a qual assunto o OA está relacionado.

[Dascalu et al. 2016] apresentam um Sistema de Recomendação baseado no poder semântico das ontologias. Inicialmente, a ontologia é povoada com instâncias (dados) de comunidades, interesses, comunidade de aprendizes, recrutadores, cargos e habilidades, obtidos a partir da plataforma *Linkedin*. Os dados relevantes são extraídos e armazenados em um grafo de ontologias. Os cargos ocupados e habilidades do usuário são explorados para fazer inferências e encontrar comunidades que possuem os mesmos interesses, apoiando tanto o aprendizado durante o curso de graduação como a inserção no meio profissional. Foram realizados testes preliminares do sistema, onde foram obtidos resultados satisfatórios, além de identificar limitações que precisam ser corrigidas no futuro.

[Sergis and Sampson 2016] almejam auxiliar os professores na seleção de OAs de repositórios existentes. Para tal, o sistema faz a recomendação em duas etapas: primeiro, por meio da construção automática dos Perfis de Competências Digitais dos professores, a qual se baseia nas ações dos mesmos dentro dos sistemas dos diferentes repositórios. Em seguida, esses perfis criados são explorados para se fazer uma seleção de OAs mais eficiente. Foram apresentados experimentos com 3 repositórios reais. Os resultados das avaliações demonstram que a abordagem proposta fornece recomendações com maior acurácia aos professores, baseadas nos seus perfis.

[Hoic-Bozic et al. 2016] propõem um modelo de aprendizagem (*blended learning*) que combina um LMS, um conjunto de ferramentas Web 2.0 e um Sistema de Recomendação de Atividades de *e-learning* (ELARS). Para tal, o modelo de aprendizado combinado foi implementado e avaliado dentro do curso “*Hypermedia Supported Education*”. Os estudantes que utilizaram o recomendador alcançaram resultados melhores em relação aos que não o utilizaram, não apenas por resultados finais, mas também por atividade. Em questionários anônimos, os alunos expressaram satisfação sobre a efetividade do modelo de aprendizado combinado e apontaram o ELARS um sistema útil.

[Limongelli et al. 2016] desenvolvem um Sistema de Recomendação voltado para os professores, no intuito de ajudá-los a montar cursos a partir de pesquisas por OAs nos repositórios mais populares. A montagem dos cursos é possibilitada a partir do sistema *Moodle*. O mecanismo de recomendação dá prioridade para OAs que foram escolhidos por outros usuários, em uma abordagem colaborativa. Aplicado em uma amostra de 25 professores, o sistema reduziu o tempo necessário para obter os objetos de aprendizagem nos repositórios, sendo apontado como útil por 80% dos participantes do experimento.

[Sweeney et al. 2016] desenvolvem um Sistema de Recomendação que auxilia o aluno, a partir do seu desempenho, na escolha semestral das disciplinas a serem cursadas no curso de graduação. Os autores buscam técnicas de recomendação empregadas no *e-commerce* para serem utilizadas no monitoramento do progresso do aluno e processo de recomendação, procurando identificar aspectos que contribuam para a aprovação do estudante. O melhor resultado dentre vários algoritmos estudados foi obtido por uma abordagem híbrida entre o *Factorization Machines* (FM) e *Random Forests* (RF). O conjunto de estudantes utilizados no experimento foi da Universidade de George Mason.

[Zhang et al. 2017] propõem um algoritmo de recomendação para ambientes de MOOCs (*massive online open courses*). Para lidar com a esparsidade e grande volume de dados que esses ambientes de MOOCs possuem, é proposta uma abordagem baseada em redes neurais profundas. O modelo é utilizado para extrair as características do conjunto

de dados da plataforma Starc, tendo a nota do curso dos alunos como o rótulo da classe de aprendizado supervisionado. A proposta obteve melhores resultados que outros métodos, tais como recomendação baseada em conteúdo e o método da descida gradiente.

[Hassan and Hamada 2017] exploram o fato de que a maioria dos sistemas não considera informações de contexto na qual a recomendação se dá. Para lidar com esse problema, é proposta uma arquitetura de sistema que lida com informações contextuais, a ser utilizada por meio de dispositivos inteligentes como *smartphones*, para fazer as recomendações. É proposto um *framework* conceitual que pode ser executado tanto em iOS quanto em dispositivos Android. O sistema proposto, ainda apenas um modelo, utiliza o conceito de Estilos de Aprendizagem como informação contextual para melhorar as recomendações de OAs.

[Gulzar et al. 2018] apresentam um Sistema de Recomendação de cursos, construído numa abordagem híbrida que utiliza técnicas de recuperação da informação, acrescidas do auxílio de ontologia. Dentro de um conjunto de cursos são realizadas consultas que passam a ser convertidas em n-gramas, sobre os quais é utilizada a ferramenta WordNet para recuperação de palavras similares. Em outra etapa são removidas possíveis redundâncias até que por fim são extraídos cursos relacionados em um repositório com o auxílio da ontologia de curso. A acurácia das recomendações foi testada em disciplinas de um curso em uma Universidade, saindo-se melhor em comparação com outras técnicas.

[Klašnja-Milićević et al. 2018] utiliza um recomendador baseado em *tags* para Ambientes Virtuais de Aprendizagem, em que *tags* são atribuídas aos Objetos de Aprendizagem. A abordagem foi avaliada no sistema de tutoria Protus, onde participaram 120 alunos do ensino médio. Foi utilizada uma técnica de clusterização para agrupar os participantes a partir de Estilos de Aprendizagem para reduzir a necessidade de processamento e memória. Ao se analisar vários algoritmos para recomendação no experimento, a técnica que obteve melhores resultados foi através de fatoração tensorial.

[da S. Dias and Wives 2019] utilizam uma proposta a ser aplicada no contexto de sistemas de *e-learning* ubíquos, que possibilitam os estudantes interagirem de várias formas no processo de aprendizagem. Para o mecanismo de recomendação, é utilizada a busca do vizinho mais próximo baseada no usuário, que é alimentada com informações a partir do comportamento do usuário em suas múltiplas interações no sistema. O desenvolvimento do sistema se fundamenta também no princípio do aluno como aquele que controla seu próprio aprendizado. Testes realizados com alunos da UFRGS na plataforma AdaptWeb mostraram a abordagem proposta com melhores resultados na recomendação.

#### 4. Análise dos Trabalhos

As tabelas 2, 3 e 4 evidenciam alguns aspectos analisados nos trabalhos.

A tabela 2 divide os trabalhos de acordo com a técnica que foi empregada no processo de recomendação. Boa parte dos Sistemas de Recomendação utiliza abordagens híbridas, isto é, estratégias combinadas, com a intenção de explorar as potencialidades e atenuar as fraquezas de cada uma das técnicas, como por exemplo, Ontologia e Filtragem Colaborativa, utilizadas em um mesmo sistema.

A tabela 3 apresenta quais trabalhos apenas propuseram o sistema, em comparação com aqueles que o aplicaram em alguma base de dados e, ou conjunto de pessoas. Mais

**Tabela 2. Abordagem/técnica empregada no Sistema de Recomendação.**

| <b>Técnica</b>         | <b>Trabalhos</b>         |
|------------------------|--------------------------|
| Filtragem Colaborativa | [10]                     |
| Baseada em Conteúdo    | [4]                      |
| Baseada em Ontologia   | [7]                      |
| Lógica Fuzzy           | [8]                      |
| Redes neurais          | [1], [3]                 |
| Híbrida                | [2], [5], [6], [9], [11] |
| Outras                 | [12], [13]               |

da metade dos trabalhos publicados de fato aplicam o sistema proposto. Há uma menor porção de trabalhos que ainda não testou o desempenho do seu recomendador em uma situação real, que possa ser comparável a outras técnicas já empregadas.

**Tabela 3. Estágio de Aplicação dos Sistemas de Recomendação.**

| <b>Estágio</b>                 | <b>Trabalhos</b>                                |
|--------------------------------|---|
| Apenas modelagem (conceitual)  | [3], [5], [7]                                   |
| Implementado, mas não aplicado | [2]   |
| Aplicado                       | [1], [4], [6], [8], [9], [10], [11], [12], [13] |

A tabela 4 separa os trabalhos de acordo com as bases de dados utilizadas para testar o Sistema de Recomendação: se a base de dados está disponível publicamente, se é restrita ao pesquisador que fez o estudo, ou se não é utilizada - caso dos trabalhos que apenas propõem um sistema, mas não o colocaram em prática até então. Percebe-se que a maioria das bases de dados são restritas e pelo que pode se depreender são pequenas, o que dificulta a comparação de um sistema proposto com outros já utilizados, ou mesmo com a recomendação avaliada pelos usuários no mundo real.

**Tabela 4. Base de dados utilizada para teste.**

| <b>Tipo</b> | <b>Trabalhos</b>                      |
|-------------|---------------------------------------|
| Público     | [1], [8]                              |
| Restrito    | [4], [6], [9], [10], [11], [12], [13] |
| Não utiliza | [2], [3], [5], [7]                    |

Por fim, a tabela 5 distingue aqueles trabalhos cujo Sistema de Recomendação foi elaborado considerando algum conceito teórico da psicologia ou pedagogia. Conforme mostra a tabela, a maioria dos trabalhos não tem como elemento balizador de seu sistema as fundamentações teóricas advindas seja da psicologia ou pedagogia, as quais são elementos norteadores e importantes no processo de ensino-aprendizagem.

Dentre os trabalhos que se valeram dessas teorias, [Imran et al. 2016] utilizam o modelo de Felder-Silverman [Felder et al. 1988] para detecção do Estilo de Aprendizagem dos alunos e sua utilização no processo de recomendação. [Hassan and Hamada 2017] também utilizam esse modelo, porém com a finalidade de

modelar informação contextual do Sistema. [Klašnja-Milićević et al. 2018] se vale do mesmo modelo para agrupar os estudantes e reduzir a necessidade de processamento. [Hoic-Bozic et al. 2016] se vale dos princípios do Processo de Bologna [Keeling 2006], uma iniciativa da Comissão Europeia para promover uma reforma educacional.

**Tabela 5. Utilização de fundamentação teórica psicopedagógica.**

| Utilização de teoria | Trabalhos                                |
|----------------------|--|
| Utiliza              | [2], [5], [9], [12], [13]                |
| Não utiliza          | [1], [3], [4], [6], [7], [8], [10], [11] |

## 5. Conclusão e Perspectivas futuras

A partir da análise realizada, não restrita apenas aos aspectos ora enfatizados, pode-se notar alguns aspectos relacionados ao conjunto dos trabalhos, os quais são listados a seguir.

- Não existem muitos trabalhos nos quais as recomendações levam em consideração ambas as preferências de alunos e tutores/professores;
- A maior parte dos trabalhos não possui alguma fundamentação teórica advinda seja da psicologia ou mesmo da pedagogia;
- A maioria dos trabalhos publicados aplicam o sistema proposto. No entanto, as bases de dados utilizadas geralmente são restritas e ao que tudo indica são pequenas, o que dificulta a comparação de um sistema proposto com outros já utilizados, ou mesmo com a recomendação avaliada pelo usuário no mundo real;
- A maioria dos Sistemas de Recomendação utiliza abordagens híbridas, isto é, estratégias combinadas, com a intenção de explorar as potencialidades e atenuar as fraquezas de cada uma das técnicas.

Tais constatações indicam algumas possibilidades e desafios a serem explorados nessa área. A primeira seria a necessidade da existência de conjuntos de dados robustos e públicos, específicos da área educacional, que possibilitassem a comparação entre diferentes técnicas quanto a sua acurácia nas recomendações. Há bases de dados disponíveis dessa natureza como a *MovieLens* [Grouplens 2018] e *Last.fm* [Kaggle 2019], porém as mesmas não são específicas ao contexto educacional.

Outro ponto importante é que o processo de ensino-aprendizagem é complexo, envolvendo diversos estudos teóricos e práticos de várias áreas do conhecimento, como a psicologia e a pedagogia. É importante haver mais sistemas de recomendação que levem em consideração esses aspectos, de modo a torná-los uma ferramenta mais integrada ao processo educacional como um todo. Sistemas que trabalhem com propostas pedagógicas e curriculares específicas, como metodologias ativas [Berbel 2011] e pensamento computacional [Wing 2006], são possibilidades aventadas.

Com relação à abordagem para implementação dos sistemas, uma seara a ser melhor explorada é a de Sistemas de Recomendação multiobjetivo. Embora existam trabalhos na área, como [Zuo et al. 2015], [Wang et al. 2016] e [Ribeiro et al. 2014], eles não tratam de modo específico o contexto educacional, que tem as suas particularidades. Há muitas situações conflitantes nesse contexto que poderiam ser tratadas numa abordagem

multiobjetivo, por exemplo, as preferências dos alunos e dos seus professores, a escolha entre o OA mais popular e outro pouco conhecido, mas que teria potencial utilização.

As análises realizadas mostram a importância dos Sistemas de Recomendação no novo paradigma educacional do *e-learning*, que tem crescido vertiginosamente. Foi possível identificar desafios a serem superados na área para que se realize uma melhor comparação entre os diferentes trabalhos conduzidos pela comunidade científica. Também foram identificadas possibilidades a serem exploradas nesse domínio da Educação, que demonstra ser esse um campo promissor e em crescimento.

## Referências

- Aamodt, A. and Plaza, E. (1994). Case-based reasoning: Foundational issues, methodological variations, and system approaches. *AI communications*, 7(1):39–59.
- Berbel, N. A. N. (2011). As metodologias ativas e a promoção da autonomia de estudantes. *Semina: Ciências Sociais e Humanas*, 32(1):25–40.
- Bobadilla, J., Ortega, F., Hernando, A., and Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-Based Systems*, 46:109–132.
- D C M, I. and Others (2008). Dcmi metadata terms. *World Wide Web electronic publication*.
- da S. Dias, A. and Wives, L. K. (2019). Recommender system for learning objects based in the fusion of social signals, interests, and preferences of learner users in ubiquitous e-learning systems. *Personal and Ubiquitous Computing*, 23(2):249–268.
- Dascalu, M.-I., Bodea, C.-N., Mihailescu, M. N., Tanase, E. A., and Ordoñez de Pablos, P. (2016). Educational recommender systems and their application in lifelong learning. *Behaviour & Information Technology*, 35(4):290–297.
- Felder, R. M., Silverman, L. K., et al. (1988). Learning and teaching styles in engineering education. *Engineering education*, 78(7):674–681.
- Grouplens (2018). Movielens Latest Datasets.
- Gulzar, Z., Leema, A. A., and Deepak, G. (2018). PCRS: Personalized Course Recommender System Based on Hybrid Approach. *Procedia Computer Science*, 125:518–524.
- Hassan, M. and Hamada, M. (2016). Enhancing learning objects recommendation using multi-criteria recommender systems. In *2016 IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALE)*, pages 62–64. IEEE.
- Hassan, M. and Hamada, M. (2017). Smart media-based context-aware recommender systems for learning: A conceptual framework. In *2017 16th International Conference on Information Technology Based Higher Education and Training (ITHET)*, pages 1–4. IEEE.
- Hoic-Bozic, N., Holenko Dlab, M., and Mornar, V. (2016). Recommender System and Web 2.0 Tools to Enhance a Blended Learning Model. *IEEE Transactions on Education*, 59(1):39–44.
- IEEE (2002). Learning Technology Standards Committee (LTSC).

- Imran, H., Belghis-Zadeh, M., Chang, T.-W., Kinshuk, and Graf, S. (2016). PLORS: a personalized learning object recommender system. *Vietnam Journal of Computer Science*, 3(1):3–13.
- IMS (2019). Ims global learning consortium.
- Kaggle (2019). last.fm dataset — Kaggle.
- Katarya, R. and Verma, O. P. (2018). Recommender system with grey wolf optimizer and FCM. *Neural Computing and Applications*, 30(5):1679–1687.
- Keeling, R. (2006). The bologna process and the lisbon research agenda: the european commission’s expanding role in higher education discourse. *European journal of education*, 41(2):203–223.
- Klašnja-Milićević, A., Ivanović, M., Vesin, B., and Budimac, Z. (2018). Enhancing e-learning systems with personalized recommendation based on collaborative tagging techniques. *Applied Intelligence*, 48(6):1519–1535.
- Limongelli, C., Lombardi, M., Marani, A., Sciarrone, F., and Temperini, M. (2016). A recommendation module to help teachers build courses through the Moodle Learning Management System. *New Review of Hypermedia and Multimedia*, 22(1-2):58–82.
- Ribeiro, M. T., Ziviani, N., Moura, E. S. D., Hata, I., Lacerda, A., and Veloso, A. (2014). Multiobjective Pareto-Efficient Approaches for Recommender Systems. *ACM Transactions on Intelligent Systems and Technology*, 5(4):1–20.
- Ricci, F., Rokach, L., and Shapira, B. (2015). Recommender Systems: Introduction and Challenges. In *Recommender Systems Handbook*, pages 1–34. Springer US, Boston, MA.
- Santos, M., Andrade, F., da Silva, J. M. C., and Imran, H. (2016). Learning Object Recommendation System Evaluation. In *2016 IEEE 16th International Conference on Advanced Learning Technologies (ICALT)*, pages 412–413. IEEE.
- Sergis, S. and Sampson, D. G. (2016). Learning Object Recommendations for Teachers Based On Elicited ICT Competence Profiles. *IEEE Transactions on Learning Technologies*, 9(1):67–80.
- Sweeney, M., Rangwala, H., Lester, J., and Johri, A. (2016). Next-Term Student Performance Prediction: A Recommender Systems Approach.
- Wang, S., Gong, M., Li, H., and Yang, J. (2016). Multi-objective optimization for long tail recommendation. *Knowledge-Based Systems*, 104:145–155.
- Wing, J. M. (2006). Computational thinking. *Communications of the ACM*, 49(3):33–35.
- Yao, X. (1999). Evolving artificial neural networks. *Proceedings of the IEEE*, 87(9):1423–1447.
- Zhang, H., Yang, H., Huang, T., and Zhan, G. (2017). DBNCF: Personalized Courses Recommendation System Based on DBN in MOOC Environment. In *2017 International Symposium on Educational Technology (ISET)*, pages 106–108. IEEE.
- Zuo, Y., Gong, M., Zeng, J., Ma, L., and Jiao, L. (2015). Personalized Recommendation Based on Evolutionary Multi-Objective Optimization [Research Frontier]. *IEEE Computational Intelligence Magazine*, 10(1):52–62.

